



**HAL**  
open science

# Contribution à la détection et à l'analyse des signaux EEG épileptiques : débruitage et séparation de sources

Rebeca Romo-Vázquez

## ► To cite this version:

Rebeca Romo-Vázquez. Contribution à la détection et à l'analyse des signaux EEG épileptiques : débruitage et séparation de sources. Traitement du signal et de l'image [eess.SP]. Institut National Polytechnique de Lorraine, 2010. Français. NNT : 2010INPL005N . tel-01748858v2

**HAL Id: tel-01748858**

**<https://theses.hal.science/tel-01748858v2>**

Submitted on 7 May 2010

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Contribution à la détection et à l'analyse des signaux  
EEG épileptiques : débruitage et séparation de sources

THÈSE

présentée et soutenue publiquement le 24 février 2010

pour l'obtention du

Doctorat de l'Institut National Polytechnique de Lorraine


Spécialité Automatique, Traitement du signal et des Images, Génie informatique

par

Rebeca del Carmen ROMO VÁZQUEZ

Composition du jury

<i>Rapporteurs :</i>	Sylvie CHARBONNIER	GIPSA-lab, Université Joseph Fourier, Grenoble
	Christian VASSEUR	LAGIS, Université des Sciences et Technologies de Lille
<i>Examineurs :</i>	Philippe DERAMBURE	Laboratoire de physiologie, Faculté de Médecine, Lille 2
	Valérie LOUIS-DORR	CRAN, Nancy Université
	Didier MAQUIN	CRAN, Nancy Université
	Radu RANTA	CRAN, Nancy Université
<i>Invité :</i>	Louis MAILLARD	CRAN, CHU de Nancy



Mis en page avec la classe thloria.

## Remerciements

Les travaux de recherche présentés dans ce mémoire ont été effectués au Centre de Recherche en Automatique de Nancy (CRAN), Unité Mixte de Recherche Nancy-Université, CNRS (UMR 7039), dans le groupe thématique Ingénierie Pour la Santé (IPS).

Je tiens à remercier mes rapporteurs Madame Sylvie CHARBONNIER et Monsieur Christian VASSEUR pour m'avoir fait l'honneur d'évaluer mes travaux de recherche, et pour leurs remarques qui m'ont permis d'améliorer ce manuscrit. Merci également à Monsieur Philippe DERAMBURE et Monsieur Louis MAILLARD pour l'honneur qu'ils me font de participer à mon jury de thèse.

Ce travail a été effectué sous la direction de Monsieur Didier MAQUIN, Madame Valérie LOUIS-DORR et Monsieur Radu RANTA. Je les remercie pour m'avoir fait bénéficier de leur expérience et de leurs compétences et pour leur patience notamment pendant l'étape de rédaction.

Un grand merci à Monsieur MAQUIN pour tous vos conseils précieux et pour m'avoir appris les subtilités de la langue française et notamment du langage scientifique.

Mes sincères remerciements vont à Valérie pour votre soutien, votre disponibilité et vos précieux conseils scientifiques apportés à ce travail.

Comment ne pas exprimer toute ma gratitude à Radu pour m'avoir fait confiance malgré mes connaissances, plutôt légères, en traitement du signal au début de ma thèse. Je te remercie profondément pour m'avoir encadrée, guidée, encouragée et conseillée pendant toutes ces années avec ta bonne humeur, ta disponibilité et surtout toutes tes qualités humaines remarquables qui m'ont permis d'avancer dans les meilleures conditions. Laconiquement, MERCI!

Je tiens à remercier les médecins neurologues qui ont beaucoup contribué à ces travaux, Monsieur Jean-Pierre VIGNAL et très particulièrement Monsieur Louis MAILLARD pour son aide si précieuse et sa disponibilité. Un grand merci aussi à Laurent KOESSLER pour son aide.

Je remercie mes collègues du laboratoire : du début, Yahir, Juanito, Gabriel, Gilberto, Diego, Yannick, Sophie, Emilie, Ivan. Et à ceux de la fin, qui ont rendu l'étape de rédaction plus légère Hugo, Ricardo, Christophe, Julie et Nedja (particulièrement pour les réunions de filles du lundi matin et pour toutes les corrections du français).

Je remercie également mes amis mexicains pour leur soutien et leur amitié, Silvia et Pedro (qui m'ont aidé depuis mon arrivée, même sans me connaître), Yahir, Juanito, Dora, Sinuhe, Joel, Gabriel, Vicky, Oscar, Guille, Evaristo et les mexicains adoptés : Diego, Pilar,

Yolanda et Anna.

Merci à Gregory et Arnaud pour leur aide et leur amitié.

Je tiens à remercier le peuple du Mexique pour le support financier qu'il m'a accordé pour la réalisation de cette thèse à travers CONACyT (Consejo Nacional de Ciencia y Tecnología).

A toute ma famille, ma belle famille et mes amis au Mexique pour leur soutien et leur intérêt.

Bien évidemment, je ne pourrais terminer sans adresser un immense merci à mes parents Efraín et Carmen, ma sœur Avenilde et mes frères Israel et Jose Efraín qui ont veillé sur moi depuis toujours, qui m'ont soutenue sans faille dans tous mes projets et qui ont accepté mes choix sans pour autant toujours les comprendre ... MIL GRACIAS por ser y estar !

Sans oublier Hugo, que je remercie du fond du cœur, je te dois ce travail ... Tu m'as toujours soutenue durant toutes ces années. Merci mille fois pour notre complicité, toutes nos joies et nos efforts communs et surtout ta compréhension ... Por el placer de coincidir ... mil gracias !

Enfin, mes plus grands remerciements reviennent à mon petit André Ephraïm, arrivé au milieu de cette thèse, pour rendre ma vie plus heureuse et intéressante, pour tes sourires qui font de chaque matin le meilleur moment de la journée.

Merci à Dieu pour les opportunités...

*À mes parents*

*À Hugo*

*À André Ephrain*



# Table des matières

<b>Introduction</b>	<b>1</b>
<b>Chapitre 1 Contexte médical et problématique</b>	<b>5</b>
1.1 Contexte médical . . . . .	5
1.1.1 Le cerveau : bases anatomiques et physiologiques . . . . .	5
1.1.1.1 Anatomie du cerveau . . . . .	5
1.1.1.2 Physiologie cérébrale . . . . .	7
1.1.1.3 L'activité électromagnétique cérébrale . . . . .	7
1.1.2 L'épilepsie . . . . .	8
1.1.2.1 Type de crise . . . . .	10
1.1.2.2 Les mécanismes épileptiques . . . . .	11
1.1.2.3 Les traitements . . . . .	11
1.1.3 Mesure de l'activité cérébrale . . . . .	13
1.1.3.1 Les méthodes non invasives . . . . .	14
1.1.3.2 Les méthodes semi-invasives . . . . .	25
1.1.3.3 Les méthodes invasives . . . . .	25
1.1.3.4 La neuro-imagerie . . . . .	27
1.2 Objectifs et problématique . . . . .	29
1.2.1 Objectifs médicaux . . . . .	30
1.2.2 Objectifs scientifiques . . . . .	31
1.2.3 Problématique . . . . .	34
1.2.3.1 Séparation de sources . . . . .	34
1.2.3.2 Identification et élimination automatique d'artéfacts . . . . .	35
1.2.3.3 Débruitage par ondelettes . . . . .	37
1.2.3.4 Chaîne de traitement . . . . .	37
1.3 Plan de la thèse . . . . .	38



<b>Chapitre 2 Séparation de sources</b>	<b>41</b>
2.1 SAS pour l'identification des artéfacts en EEG . . . . .	42
2.1.1 Les types de mélange . . . . .	42
2.1.2 Familles d'algorithmes . . . . .	43
2.1.3 Limites de la séparation de sources . . . . .	45
2.1.4 Estimation de la matrice de séparation . . . . .	47
2.1.4.1 Blanchiment (décorrélation) . . . . .	47
2.1.4.2 Séparation de sources par statistique d'ordre supérieur – Analyse en Composantes Indépendantes . . . . .	50
2.1.4.3 Séparation de sources par statistique d'ordre deux . . . . .	54
2.1.4.4 Modifications (optimisations) des méthodes classiques . . . . .	58
2.1.4.5 Méthodes de séparation de sources et EEG . . . . .	60
2.2 Méthodologie de simulation . . . . .	61
2.2.1 Critère d'évaluation pour la SAS . . . . .	62
2.2.2 Signaux de test . . . . .	63
2.2.2.1 Simulation de sources d'activité normale . . . . .	63
2.2.2.2 Simulation de l'EEG normal . . . . .	64
2.3 Résultats . . . . .	66
2.3.1 Signaux sans bruit, matrice de mélange inconnue . . . . .	67
2.3.2 Signaux bruités, matrice de mélange commune . . . . .	70
2.3.3 Signaux bruités, matrice de mélange inconnue . . . . .	76
2.3.4 Illustration sur signaux EEG réels . . . . .	79
2.4 Conclusion . . . . .	81
<b>Chapitre 3 Identification automatique de sources d'artéfacts</b>	<b>85</b>
3.1 Classification des sources EEG : état de l'art . . . . .	86
3.1.1 Extraction des caractéristiques . . . . .	87
3.1.2 Classification . . . . .	88
3.1.2.1 Système expert . . . . .	89
3.1.2.2 Classification supervisée . . . . .	89
3.2 Classification des sources EEG : mise en œuvre . . . . .	91
3.2.1 Acquisition d'EEG . . . . .	91
3.2.1.1 Montage d'acquisition . . . . .	91
3.2.1.2 Durée d'acquisition . . . . .	92
3.2.1.3 Elimination de la ligne de base . . . . .	92

---

3.2.2	Extraction des caractéristiques . . . . .	93
3.2.2.1	Caractéristiques spatiales . . . . .	93
3.2.2.2	Similarité avec des signaux de référence . . . . .	95
3.2.2.3	Caractéristiques fréquentielles . . . . .	96
3.2.3	Classification . . . . .	96
3.2.3.1	Système expert . . . . .	97
3.2.3.2	Classification . . . . .	99
3.3	Validation . . . . .	100
3.3.1	Evaluation quantitative . . . . .	101
3.3.2	Validation médicale . . . . .	102
3.4	Résultats . . . . .	103
3.4.1	Evaluation quantitative . . . . .	104
3.4.2	Evaluation clinique . . . . .	109
3.5	Conclusion . . . . .	117
<b>Chapitre 4 Débruitage par ondelettes</b>		<b>119</b>
4.1	Débruitage par ondelettes – état de l’art . . . . .	119
4.1.1	Décomposition en ondelettes . . . . .	120
4.1.1.1	Signal informatif . . . . .	122
4.1.1.2	Bruit aléatoire . . . . .	123
4.1.2	Débruitage par seuillage des coefficients d’ondelettes . . . . .	123
4.1.2.1	Algorithme général du débruitage . . . . .	124
4.1.2.2	Calcul du seuil . . . . .	125
4.1.2.3	Stratégies de seuillage . . . . .	126
4.2	Combinaisons de méthodes de traitement : SAS, débruitage et classification	128
4.2.1	Chaînes de traitement . . . . .	130
4.2.2	Ordonnancement : débruitage et séparation . . . . .	132
4.2.2.1	Simulation . . . . .	137
4.2.3	Ordonnancement : débruitage et reconstruction . . . . .	140
4.2.3.1	Simulation . . . . .	142
4.3	Débruitage des EEG réels . . . . .	149
4.3.1	Validation . . . . .	151
4.3.2	Résultats . . . . .	151
4.4	Conclusion . . . . .	152

<b>Chapitre 5 Application clinique : EEG épileptiques</b>	<b>155</b>
5.1 Séparation, classification et débruitage des EEGs critiques . . . . .	155
5.1.1 Base de données . . . . .	155
5.1.2 Méthodologie de traitement et analyse . . . . .	156
5.1.2.1 Séparation de sources . . . . .	156
5.1.2.2 Classification des sources estimées . . . . .	156
5.1.2.3 Débruitage . . . . .	156
5.1.2.4 Validation médicale . . . . .	157
5.1.3 Résultats . . . . .	157
5.1.4 Performances de classification : sources cérébrales . . . . .	163
5.1.5 Classification en 5 classes . . . . .	168
5.1.5.1 Résultats de la classification . . . . .	168
5.2 Application des algorithmes de synchronisation . . . . .	174
5.2.1 Méthodes d'estimation de relations inter-voies . . . . .	175
5.2.2 Effet du prétraitement sur les relations inter-voies d'EEG réels . . .	176
5.3 Conclusion . . . . .	184
<b>Conclusion générale et perspectives</b>	<b>189</b>
<b>Annexe A</b>	<b>195</b>
<b>Bibliographie</b>	<b>231</b>

# Introduction

L'électroencéphalographie (EEG) est une des techniques les plus utilisées pour l'étude et la mise en évidence de l'activité électrique du cerveau. Elle demeure incontournable pour le diagnostic des maladies telle que l'épilepsie. Cette maladie est une affection chronique du cerveau qui touche toutes les populations du monde. Elle se caractérise par des crises récurrentes qui sont la manifestation physique de décharges électriques excessives et soudaines, généralement brèves et répétitives, générées par une population de neurones. Ces décharges peuvent avoir lieu dans différentes parties du cerveau. Les crises peuvent varier en intensité mais également en localisation et en volume, elles peuvent entraîner de brèves pertes d'attention ou de petites secousses musculaires ou même conduisent à des convulsions sévères et prolongées.

Dans le monde, plus de 40 millions de personnes sont concernées par l'épilepsie selon la fondation française pour la recherche sur l'épilepsie [FFRE, 2009]. En France, environ 450 000 épileptiques sont répertoriées dont 250 000 ont moins de 20 ans. L'épilepsie est après la migraine, la première raison de consultation chez les neurologues.

Ce qui précède montre la nécessité et l'importance d'étudier l'activité cérébrale et l'activité épileptique proprement dite. L'EEG comparé aux autres techniques d'investigation, fournit des informations en temps réel et avec une très bonne résolution temporelle, de l'ordre de la milliseconde. Ce type d'enregistrement présente toutefois de gros inconvénients, car les signaux sont extrêmement perturbés par différents types d'activités extra-cérébrales (oculaires, musculaires, cardiaques, etc.), appelées artéfacts, et par du bruit, appelé bruit de fond. Ces artéfacts ont parfois une très grande amplitude et noient l'activité épileptique réelle. Le travail présenté dans ce mémoire s'inscrit dans l'aide au diagnostic neurologique, plus précisément pour le diagnostic de l'épilepsie et plus particulièrement dans l'étape de prétraitement des EEG de surface.

En effet, l'analyse des EEG de surface est une étape importante dans le raisonnement scientifique et clinique qui mène au diagnostic. Or les EEG de surface sont très souvent

altérés par des perturbations extra-cérébrales et des perturbations électromagnétiques en général. Ces perturbations présentent des caractéristiques qui nuisent à l'interprétation. Parfois très énergétiques par rapport aux signaux d'intérêt, elles sont également présentes dans les mêmes bandes spectrales.

Dans cette thèse, nous visons donc à développer une méthodologie de traitement dédiée à l'identification d'artéfacts (mouvements oculaires, clignements, activité cardiaque, musculaire) et du bruit qui perturbent la lecture, l'interprétation et l'analyse des enregistrements d'EEG (visuelle et automatique), suivi de leur élimination avec une perte minimale d'information. L'automatisation de l'identification et de l'élimination d'artéfacts permettra par la suite la reconstruction des signaux d'EEG dits "propres".

Cette méthodologie est basée sur la séparation aveugle de sources (SAS) en combinaison avec des méthodes de classification : un système expert et l'analyse discriminante (basée sur la distance de Mahalanobis et le classificateur de Bayes). La classification traite des caractéristiques spatiales, temporelles et fréquentielles. En ce qui concerne la validation, les algorithmes de séparation de sources ont, dans un premier temps, été éprouvés sur des signaux simulés (sources et matrice de mélange). La composition fonctionnelle SAS et la classification appliquées aux signaux réels ont bénéficié d'une validation par expertise médicale.

Dans un second temps, nous avons proposé d'évaluer le bénéfice que pourraient apporter à ces méthodes l'introduction d'une étape de débruitage dans la procédure de pré-traitement. Cette combinaison de techniques de type séparation de sources, classification supervisée et débruitage nécessite bien évidemment une validation à chaque étape de traitement pour définir le choix des algorithmes et de leur paramètres. La mise en place d'une méthodologie intégrant d'une manière optimale ces trois techniques (séparation de sources, classification supervisée et débruitage par ondelettes) constitue l'apport principal de cette thèse. L'optimisation de cette méthodologie sera faite à la fois en terme de fonctions individuelles (meilleurs algorithmes de chaque domaine pour l'application) et en terme de structure et d'ordonnement (ordre des étapes de traitement).

Les différentes constituantes de la chaîne de traitement résultante, ainsi que leur combinaison, nécessitent le développement d'une méthodologie de validation, focalisée d'une part sur les méthodes de traitement individuelles et d'autre part sur les résultats globaux, surtout en termes d'exploration médicale. Cette validation peut être effectuée partiellement sur des signaux simulés.

L'exercice devient beaucoup plus périlleux pour évaluer ce traitement sur des signaux réels : la validation est élaborée à partir de l'expertise médicale, notamment en fonction

---

de la facilité d'interprétation et de la qualité diagnostique des EEG traités (en termes d'information préservée ou mise en évidence). Cette évaluation médicale est faite sur une base de données d'EEG réels contenant des crises d'épilepsie expertisées. Enfin, nous présentons également dans ce mémoire une évaluation objective du pré-traitement à travers l'évaluation des améliorations apportées à un outil classique dans l'analyse des EEG : les méthodes de synchronisation et leurs applications de type détection et/ou latéralisation automatique des crises.



# Chapitre 1

## Contexte médical et problématique

La première partie de ce chapitre présente un panorama général du contexte médical : le cerveau, l'épilepsie (les origines, les traitements et les bases neurophysiologiques), les techniques d'analyse des signaux épileptiques et les différents artefacts qui perturbent les signaux d'EEG. La deuxième partie présente la problématique médicale et les objectifs scientifiques de cette thèse.

### 1.1 Contexte médical

#### 1.1.1 Le cerveau : bases anatomiques et physiologiques


Le cerveau est l'organe le plus complexe du corps humain. Il régit notre comportement, nos actions et nos pensées, nos désirs et nos instincts. Grâce à lui, nous pouvons voir, sentir ou entendre, parler et marcher, analyser et comprendre le monde qui nous entoure. Pour cela, il suscite autant d'interrogations que de fascination.

##### 1.1.1.1 Anatomie du cerveau

Cerveau est un terme qui désigne le tissu que l'on trouve dans le crâne. Le cerveau possède deux moitiés relativement symétriques appelées des hémisphères, l'un à droite et l'autre à gauche (figure 1.1(a)). Toute la couche externe du cerveau, la substance grise qui présente des circonvolutions complexes en périphérie, est appelée le cortex cérébral. Le cortex de chaque hémisphère est divisé en quatre lobes (figure 1.1(b)) : le lobe pariétal, le lobe occipital, le lobe frontal et le lobe temporal dont l'appellation est directement inspirée du nom des os crâniens qui les recouvrent [Kolb et Whishaw, 2002].

Les lobes sont impliqués dans différentes fonctions [Westen et Garitte, 2000] :





**FIGURE 1.1.** Le cerveau : représentation de ces deux hémisphères (a) et des différents lobes qui le constituent (b)

- Les lobes occipitaux, localisés à l’arrière du cortex, sont spécialisés dans la vision.
- Les lobes pariétaux sont situés à l’avant des lobes occipitaux. Ils sont impliqués dans le sens du toucher, dans la détection de mouvements dans l’environnement et la localisation des objets dans l’espace.
- Les lobes frontaux sont impliqués dans le mouvement, l’attention, la planification, les compétences sociales, la pensée abstraite, la mémoire et certains aspects de la personnalité.

- Les lobes temporaux sont importants dans l’audition, le langage et la reconnaissance visuelle des objets.

### 1.1.1.2 Physiologie cérébrale

Les cellules en charge du traitement de l’information au sein du cerveau sont les neurones. Le neurone est un type de cellule constituant l’unité fonctionnelle du système nerveux. On estime que le cerveau humain comprend environ 100 milliards ( $10^{11}$ ) de neurones [Williams et Herrup, 1988]. Les neurones assurent la génération et la transmission d’un signal que l’on nomme l’influx nerveux.

Les neurones ont une organisation cellulaire de base qui ressemble à celle des autres cellules. Ils s’en distinguent toutefois nettement par leur spécialisation pour la communication intercellulaire. Cette propriété se manifeste dans leur morphologie générale.

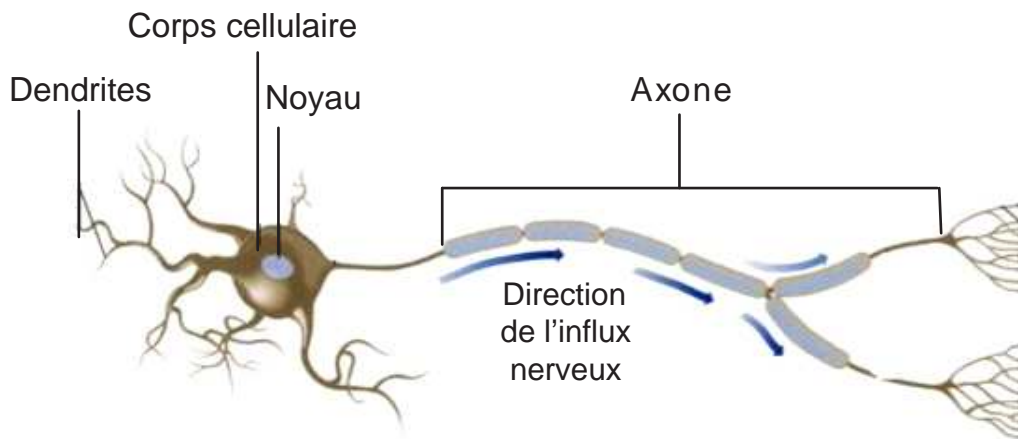
Un neurone est divisé en plusieurs régions ayant chacune une fonction propre (figure 1.2). Les neurones sont caractérisés par : un corps cellulaire contenant le noyau et la plupart des organites responsables de l’entretien de la cellule, un long prolongement cellulaire, l’axone, issu de la cellule, s’étendant parfois sur une longue distance et servant à transmettre des signaux à d’autres cellules ; de nombreux prolongements courts, les dendrites, qui accroissent la surface disponible pour des connexions avec les axones d’autres neurones ; de jonctions spécialisées, les synapses, entre leur axone et d’autres cellules, permettant ainsi une communication cellulaire directe.

Chaque neurone est capable d’en influencer beaucoup d’autres, de toute évidence, il faut des mécanismes extrêmement complexes et efficaces pour rendre possible la communication entre ce nombre important d’éléments. C’est ce que font les synapses, c’est-à-dire les contacts fonctionnels entre neurones. En se fondant sur le mécanisme de transmission qu’elles utilisent, on peut en distinguer deux types : les synapses électriques et les synapses chimiques.

### 1.1.1.3 L’activité électromagnétique cérébrale

Les synapses électriques sont présentes dans tout le système nerveux : elles laissent passer le courant électrique directement de façon passive d’un neurone à l’autre, par les pores de jonctions communicantes.

Les potentiels électriques enregistrés sur le scalp sont les conséquences des activités synaptiques des neurones. L’activité électrique du cerveau recueillie à la surface du scalp est due à l’activation simultanée d’un très grand nombre de neurones.



**FIGURE 1.2.** *Modèle d'un neurone*

Tous les neurones ne produisent pas d'activités électriques participant à l'EEG de surface. Ce sont surtout les cellules pyramidales [Adam *et al.*, 2000], pourtant minoritaires qui en sont capables.

Les cellules pyramidales (figure 1.3) sont disposées parallèlement les unes par rapport aux autres et perpendiculairement à la surface du manteau cortical, leur arborisation dendritique est très asymétrique avec une dendrite dite apicale<sup>1</sup> s'étendant dans la couche superficielle du cortex, alors que le soma (corps cellulaire) est plus profondément situé. La disposition parallèle de ces cellules pyramidales explique la génération d'un vecteur de densité de courant et caractérise la constitution du dipôle.


Pour qu'une activité électrique soit suffisamment ample pour devenir visible sur le scalp, il faut que des centaines de milliers de neurones se synchronisent. La surface corticale minimale active pour l'apparition d'un potentiel de scalp a été estimée à  $6\text{cm}^2$  selon [Nunez et Srinivasan, 2006].

### 1.1.2 L'épilepsie

Le terme épilepsie vient du mot grec *epilambanein*, qui signifie assaillir ou saisir violemment. L'épilepsie est une des maladies qui a eu le plus d'appellations différentes au cours de l'histoire. Au V<sup>e</sup> siècle avant J.C., les Grecs parlaient du "mal sacré". Hippocrate en a fait la description dans son traité. Il pensait qu'il s'agissait d'un dérèglement cérébral ce qui était une conception révolutionnaire. Chez les romains, il s'agissait du "mal

---

1. Une dendrite apicale est une dendrite qui émerge de l'apex d'une cellule pyramidale [Greenstein, 2000]



**FIGURE 1.3.** Représentation d'une cellule pyramidale. L'excitation d'une cellule pyramidale par ses dendrites apicales crée une électronégativité apicale par rapport au soma qui devient électro-positif. Les lignes en pointillé représentent les lignes isopotentiellles. Cette différence de potentiels produit un courant extracellulaire indiqué par les lignes continues qui sont perpendiculaires aux lignes de potentiels

des esclaves".

Ce n'est qu'à la fin du *XIX*<sup>e</sup> siècle, après des siècles d'obscurantisme, que l'épilepsie prend enfin sa place dans la famille des maladies neurologiques et c'est à Hughlings Jackson à qui nous devons la première conception pathogénique de la crise épileptique qu'il définit en 1873, comme la survenue soudaine d'une décharge, excessive et rapide d'une population plus ou moins étendue de neurones qui constituent la substance grise de l'encéphale. Il émet aussi l'idée que le type de crise varie en fonction de la localisation et de la nature de ces décharges.

Selon l'Organisation Mondiale de la Santé [OMS, 2009] l'épilepsie est une affection chronique du cerveau qui touche toutes les populations du monde. Elle se caractérise par des crises récurrentes qui sont la manifestation physique de décharges électriques excessives et soudaines, généralement brèves, dans un groupe de cellules cérébrales (neurones). Ces décharges peuvent avoir lieu dans différentes parties du cerveau. Les crises

peuvent varier en intensité, allant de brèves pertes d'attention ou de petites secousses musculaires à des convulsions sévères et prolongées. Leur fréquence est également variable.

Dans le monde, plus de 40 millions de personnes sont concernées par l'épilepsie selon la fondation française pour la recherche sur l'épilepsie [FFRE, 2009]. En France, environ 450 000 épileptiques sont répertoriées dont 250 000 ont moins de 20 ans et 5% de la population est susceptible de faire une crise, un jour. De fait, chaque jour, 100 personnes présentent une première crise, soit près de 40 000 par an. Une fois sur deux, cette crise peut préjuger d'une maladie épileptique qui est, après la migraine, la première raison de consultation chez les neurologues.

#### 1.1.2.1 Type de crise

Pendant les crises d'épilepsie, des changements brefs et soudains de l'activité électrique du cerveau se produisent. Cette décharge électrique anormale peut avoir lieu soit dans une zone précise du cerveau, soit dans son ensemble. La distinction entre crises partielles et crises généralisées repose sur le caractère localisé ou diffus de cette décharge à son origine. Lorsque la décharge est localisée, les signes sont en rapport avec les fonctions de la zone cérébrale concernée. De ce fait, les crises sont classées en deux types :

- Les crises partielles n'affectent que certaines parties du cerveau et donc des commandes cérébrales. Elles peuvent se traduire par des troubles moteurs, des troubles sensoriels et sensitifs, des troubles de la mémoire ou de la conscience. Certaines de ces crises partielles peuvent évoluer vers une crise généralisée tonico-clonique.
- Les crises généralisées, parmi lesquelles
  - Les crises tonico-cloniques : ce sont les plus connues, les plus impressionnantes mais non les plus fréquentes. Elles se manifestent par une perte de connaissance avec chute, mouvements convulsifs, morsure de la langue, etc.
  - Les absences : elles se manifestent par une brève rupture de contact (quelques secondes) se traduisant par une fixité du regard. Elles sont parfois accompagnées de mâchonnements ou de gestes involontaires et inadaptés appelés automatismes. Les absences peuvent se répéter d'une manière fréquente au cours de la journée.

### 1.1.2.2 Les mécanismes épileptiques

Selon l'origine de l'épilepsie, les crises partielles et les crises généralisées peuvent être symptomatiques, cryptogéniques ou idiopathiques :

- Les épilepsies symptomatiques sont dues à une lésion cérébrale : malformation congénitale, encéphalite, séquelles d'une souffrance à la naissance, traumatisme crânien, accident vasculaire cérébral, tumeur, infections du système nerveux central, maladies neurologiques évolutives, anomalies des chromosomes, etc.
- Les épilepsies cryptogéniques ; lorsque qu'une cause est suspectée, mais ne peut être prouvée par les moyens diagnostiques actuels, on parle d'épilepsie cryptogénique dont le nombre est en constante diminution du fait de l'évolution permanente des techniques d'exploration.
- Les épilepsies idiopathiques présentent un caractère génétique plus ou moins démontrable et concernent des sujets le plus souvent sans lésion cérébrale. La prédisposition génétique n'induit pas que l'épilepsie soit une maladie héréditaire. La transmission de l'épilepsie est très complexe et ne concerne qu'un petit nombre de cas.

### 1.1.2.3 Les traitements

Actuellement pour soigner les patients épileptiques, le traitement est d'abord médicamenteux. En cas d'échec de ce traitement, on propose un traitement chirurgical. Plus récemment ont été mises au point des techniques de stimulation. Les traitements qu'ils soient médicamenteux, chirurgicaux ou par stimulations, ont pour objectif la disparition des crises ou tout au moins leur diminution.

**Les médicaments** Les tentatives de traitement des crises d'épilepsie remontent à la pré-histoire. A chaque époque de l'histoire, les traitements ont découlé de la représentation que l'on se faisait de l'origine de la maladie.

A l'époque pré-hippocratique, alors que l'on considérait l'épilepsie comme une "maladie sainte", envoyée des Dieux, les "traitements" consistaient en offrandes, expiations, rituels, prescrits par des médecins-prêtres.

A l'époque hippocratique, certains médecins étaient persuadés de l'origine non divine de l'épilepsie et ont tenté de la soigner avec des méthodes "naturelles", basées sur la diététique et un mode de vie sain. Il y avait trois principes fondamentaux : règles d'alimentation, régulation des sécrétions et gymnastique corporelle.

Aujourd'hui, il y a à peu près 20 substances chimiques qui peuvent être utilisées seules ou en association, et qui ont une efficacité pharmacologique mesurée dans le traitement de l'épilepsie.

Avec les médicaments d'aujourd'hui, entre 70% et 80% des malades chez qui le diagnostic d'épilepsie est posé peuvent être traités avec succès (maîtrise complète des crises pendant plusieurs années), et donc de fait entre 20% et 30% sont résistants à la thérapie. Parmi ceux-ci, la moitié est candidate à la chirurgie [OMS, 2009; FFRE, 2009; Jallon, 2007]

**La chirurgie** La place de la chirurgie demeure extrêmement limitée. Elle s'adresse à environ la moitié des patients qui ont une épilepsie partielle pharmaco-résistante et présentant un foyer épileptogène localisé qui peut être retiré chirurgicalement sans créer de déficit fonctionnel (troubles du langage, troubles de la mémoire, ...).

La recherche de ce foyer, dite zone épileptogène, peut mettre en évidence une lésion cérébrale à l'origine des crises. Cependant, dans certains cas, aucune lésion ne peut être mise en évidence, quel que soit le moyen d'investigation.

La chirurgie de l'épilepsie est basée sur deux principes :

1. curatif : l'intervention consiste en l'ablation du foyer épileptique ou d'une zone lésée. En effet, certaines zones corticales ont des fonctions essentielles et, de ce fait, ne peuvent être enlevées. Cela limite le nombre de patients pouvant profiter d'une telle intervention.
2. palliatif : la chirurgie palliative de l'épilepsie consiste à sectionner les voies de transmission de la propagation de la décharge épileptique. Ceci permet de limiter l'ampleur des crises. Ce type d'intervention est envisagée en présence de crises généralisées avec des chutes fréquentes.

Malgré les limites évidentes des indications de la chirurgie de l'épilepsie, on estime actuellement qu'il y aurait 12 000 candidats potentiels à cette pratique en France, alors qu'une centaine d'interventions ont lieu chaque année. Les résultats de la chirurgie sont encourageants : 67% à 85 % des patients sont contrôlés, c'est-à-dire n'ont plus de crises ; les meilleurs résultats sont obtenus dans les cortectomies pour une épilepsie temporale, ce qui consiste en la résection très limitée de la zone du cerveau où a été individualisé le foyer épileptogène [Jallon, 2007].

**La stimulation** La stimulation vagale chronique intermittente consiste en la stimulation du nerf vague gauche, au moyen d'une électrode implantée et connectée à un stimula-

teur sous-cutané de type pacemaker (figure 1.4). Selon certains auteurs, la technique est prometteuse, près de 40% des patients rapportent une réduction de plus de 50% de leurs crises, avec des effets secondaires supportables (toux, raucité de la voix, douleur pharyngée). Cependant, son mécanisme d'action est encore mal connu, ce qui explique le scepticisme d'une partie de la communauté vis à vis de cette méthode.



**FIGURE 1.4.** *Stimulation du nerf vague et un stimulateur*

La stimulation magnétique externe donne aussi des résultats encourageants, et elle est plus simple à utiliser, car elle est non invasive. La stimulation, par des électrodes implantées, de certaines structures cérébrales situées soit dans le lobe temporal, soit proches des noyaux gris centraux (thalamus) est une technique plus sophistiquée, dont les résultats restent encore difficiles à apprécier [Jallon, 2007].

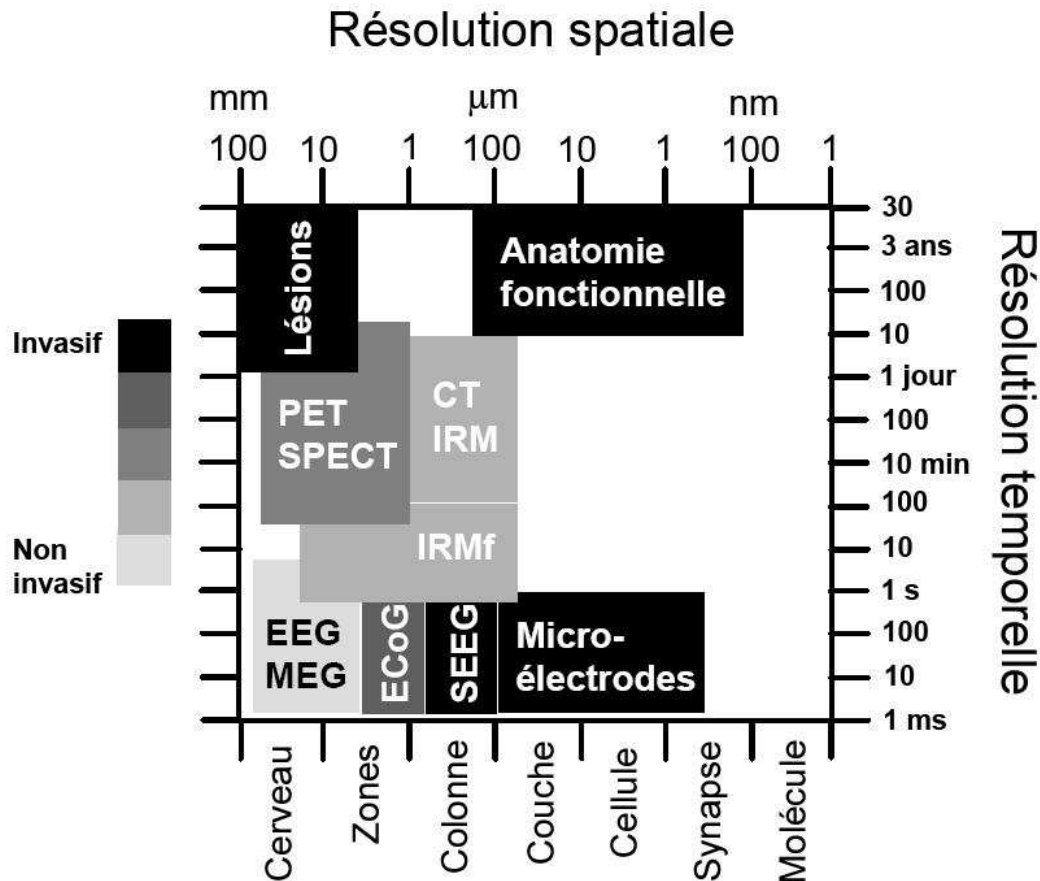
### 1.1.3 Mesure de l'activité cérébrale

Il existe plusieurs types de modalités pour explorer les activités cérébrales, la figure 1.5 [Churchland et Sejnowski, 1988] illustre la variabilité des résolutions temporelles et spatiales parmi les méthodes d'exploration cérébrales (techniques d'imagerie et techniques électrophysiologiques).

En principe ces méthodes peuvent être groupées en deux classes : l'imagerie et l'exploration électrophysiologique. Nous détaillons ici plus particulièrement des méthodes électrophysiologiques, et surtout l'électroencéphalogramme (EEG), qui est à la base de nos travaux de recherche. Les autres méthodes, la magnétoencéphalographie (MEG), l'EEG invasive (la stéréoelectroencéphalographie (SEEG) et l'électrocorticographie (ECoG)),



ainsi que les méthodes d'imagerie, seront présentées brièvement.



**FIGURE 1.5.** Schéma comparatif des résolutions temporelles et spatiales et du caractère invasif des différentes techniques d'imagerie cérébrale (EEG : Électroencéphalographie, IRM : Imagerie par Résonance Magnétique, IRMf : IRM fonctionnelle, MEG : Magnétoencéphalographie, SEEG : Stéréo Encéphalographie, TDM : Tomodensitométrie, TEMP : Tomographie par Émission Monophotonique, TEP : Tomographie par Émission de Positons)

Nous pouvons classer en trois groupes les différents modalités électrophysiologiques qui permettent d'enregistrer les signaux de l'activité électrique cérébrale : méthodes non invasives, semi-invasives et invasives.

### 1.1.3.1 Les méthodes non invasives

Parmi les méthodes d'analyse physiologiques non invasives, on distingue l'électroencéphalogramme de surface classique et la magnétoencéphalographie, qui est une tech-

nique relativement récente, nous parlerons plus précisément de ces méthodes dans les paragraphes suivants.

**L'Electroencéphalogramme (EEG).** L'électroencéphalogramme (EEG) est le moyen le plus utilisé pour mettre en évidence l'activité électrique du cerveau, donc l'activité épileptique proprement dite. Comparé aux autres techniques d'investigation, l'EEG fournit des informations en temps réel et avec une très bonne résolution temporelle, de l'ordre de la milliseconde (figure 1.5). Il demeure incontournable pour le diagnostic et la classification des épilepsies. Berger a mis cela en évidence chez l'homme en 1924 [Berger, 1929]. L'EEG est le résultat d'une différence de potentiel mesurée entre deux points. L'enregistrement entre deux points se fait grâce à des électrodes placées sur le cuir chevelu. La figure 1.6 présente un exemple d'un enregistrement d'EEG. Ces potentiels varient au cours du temps et forment des rythmes.

La morphologie des tracés dépend de l'état d'activation des neurones enregistrés et cet état d'activation va se traduire par des variations de fréquence et d'amplitude des ondes enregistrées.

**Les activités électriques cérébrales rythmiques.** Ces activités sont classées selon leur fréquence en 5 groupes : delta- $\delta$  (0.5-4Hz), thêta- $\theta$  (4-8Hz), alpha- $\alpha$  (8-13Hz), bêta- $\beta$  (13-30Hz) et gamma- $\gamma$  (supérieur à 30Hz) [Sanei et Chambers, 2007].

- **Le rythme alpha** est un rythme de la bande (ou fréquence) entre 8 – 13Hz et de 30 à 50 $\mu$ V d'amplitude, sa topographie est plus particulièrement postérieure (en arrière du vertex) dans la région occipitale. Il apparaît surtout avec les yeux fermés.
- **Les rythmes delta et thêta** (les ondes lentes). Une onde dite lente est définie arbitrairement comme étant un signal dont le contenu fréquentiel est inférieur à celui de la bande alpha. Ces ondes lentes, thêta et delta, peuvent témoigner d'un processus pathologique lésionnel ou fonctionnel sous-jacent. Dans les épilepsies partielles, elles sont fréquentes et souvent localisées dans la même région que le foyer épileptique inter-critique (les ondes thêta et delta sont largement présentes lors des variations du niveau de vigilance et, dans ces conditions, leur apparition n'est pas pathologique) [Vespignani, 1998].
- **Le rythme bêta**, de fréquence supérieure à 13 Hz, occupe les régions moyennes des deux hémisphères souvent de manière asynchrone. D'amplitude faibles (inférieure à 20 $\mu$ V), ces rythmes peuvent être masqués par les rythmes alpha (plus énergétique).

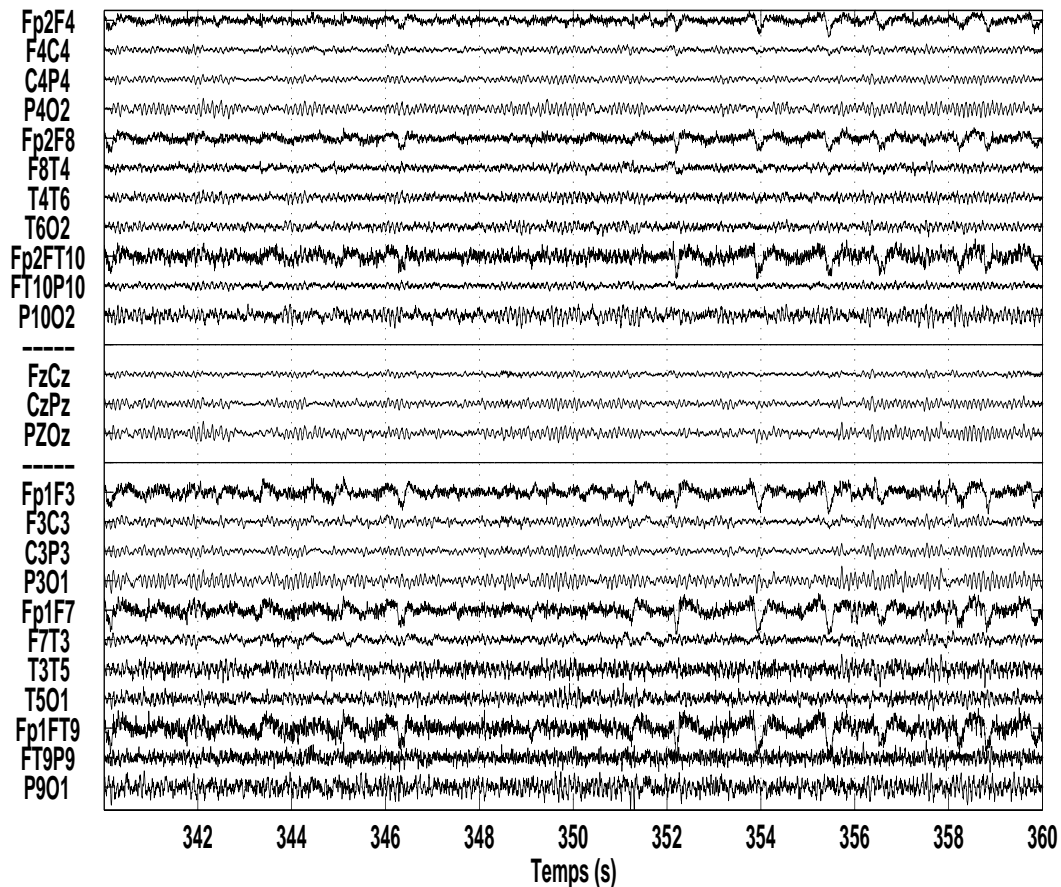


FIGURE 1.6. Exemple d'un enregistrement d'EEG en montage bipolaire

- Le rythme gamma est d'amplitude très faible et d'occurrence plus rare, la détection des ces rythmes peut être employée pour la confirmation de certaines pathologies. La figure 1.7 illustre les principaux rythmes de l'activité cérébrale ( $\alpha$ ,  $\beta$ ,  $\delta$  et  $\theta$ ).

**Les paroxysmes EEG.** Un paroxysme EEG peut être décrit comme un événement transitoire, une forme d'onde, avec un départ brutal et une fin brutale, qui atteint très rapidement son maximum amplitude, se détachant très nettement de l'activité du fond. Son amplitude est au moins deux fois supérieure à l'activité de fond. Un paroxysme EEG est de morphologie simple (la pointe et l'onde raide) ou complexe (polypointes, polypointes-ondes, pointe-onde, pointe-ondes rapide, pointe-ondes lentes). La figure 1.8 illustre un EEG avec l'apparition de paroxysmes (de type pointes biphasiques).




FIGURE 1.7. Principaux rythmes extraits d'un EEG réel


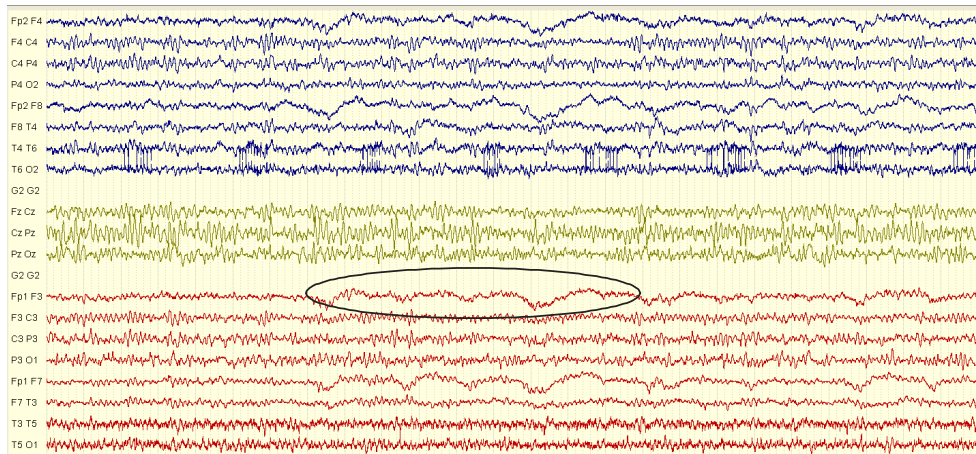


FIGURE 1.8. Paroxysmes EEG (montage référentiel moyen)

**Les perturbations.** Les principales perturbations présentes dans les EEGs sont les artéfacts et le bruit :


- **Les artéfacts** : Les artéfacts sont des activités électrophysiologiques non cérébrales d'origine corporelle enregistrés par l'EEG, comme des mouvements oculaires, des clignements, des activités musculaires, des activités cardiaques, etc.
- **Les mouvements oculaires.** Les mouvements oculaires sont les mouvements vo-

lontaires ou involontaires de ou des yeux provoquant des différences de potentiels lentes sur les électrodes frontales ; cela entraîne des distorsions, souvent significatives, du signal EEG rendant son interprétation problématique (figure 1.9).



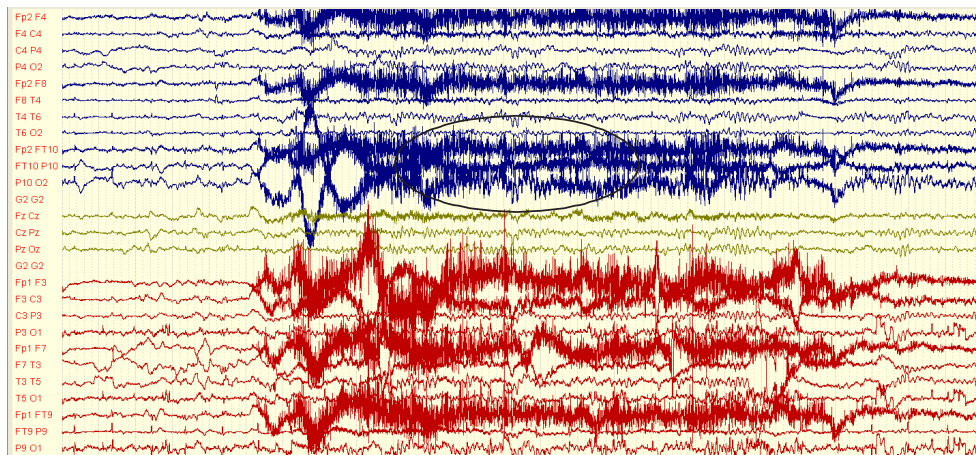
**FIGURE 1.9.** Exemple de signaux contaminés par des artefacts de mouvements oculaires (montage bipolaire)

- **Les clignements.** Les clignements sont les mouvements mécaniques de la paupière. Chaque clignement ou chaque fermeture des paupières entraîne une grande déflexion du signal, due au mouvement des paupières. Ces artefacts apparaissent principalement sur les électrodes de la zone frontale (sur le montage bipolaire, figure 1.10). En cas de montage référentiel commun, leur répartition sur les voies de mesure dépend du placement de l'électrode de référence.



**FIGURE 1.10.** Exemple de signaux perturbés par des artefacts de clignements (montage bipolaire)

- **L'artéfact musculaire.** Les muscles de la tête ou de la face peuvent produire des activités musculaires qui se traduisent par des phénomènes électriques rapides. Les artéfacts musculaires génèrent des signaux de hautes fréquences, en grande partie d'amplitude supérieure à l'activité EEG mesurable, en masquant l'activité cérébrale (figure 1.11).




**FIGURE 1.11.** Exemple de signaux perturbés par des artéfacts d'origine musculaire (montage bipolaire)


- **Les activités cardiaques.** Chaque battement cardiaque entraîne un léger mouvement de la tête, non perçu communément. Localement, les électrodes situées à proximité d'une artère peuvent être sujettes à un mouvement supplémentaire et générer un artéfact. L'aspect de ces artéfacts peut parfois ressembler à celui de pointes inter-critiques et il devient alors très difficile de les différencier (figure 1.12).
- **Le bruit.** On appelle bruit toute composante du signal mesuré non identifié comme un artéfact et qui n'est pas informative pour l'application. Nous avons deux types de bruit : l'activité qui n'a généralement pas d'explication clinique connue pour le moment, comme les fréquences au-dessus de 30 Hz (les hautes fréquences) et le bruit de mesure, dû essentiellement à l'instrumentation (électrodes, fils électriques, alimentation, etc.) et à l'environnement.

**Les électrodes.** Les électrodes sont de petites tailles, chacune de ces électrodes est reliée à un enregistreur numérique qui recueille et stocke le signal (figure 1.13).

Les électrodes sont de 3 types [Vespignani, 1998] :



**FIGURE 1.12.** Exemple des signaux perturbés par des artéfacts d'activité cardiaque (montage bipolaire)



**FIGURE 1.13.** L'électroencéphalogramme

– **L'électrode tampon**

A la forme d'un petit dôme de  $2\text{cm}^2$  à la base, en argent chlorure recouvert d'un tampon de tissu imbibé d'eau saline, est simplement placée sur le scalp après dégraissage du cuir chevelu et application d'une pâte conductrice, elle est maintenue par un casque de caoutchouc épousant le crâne du sujet.

– **L'électrode cupule**

A la forme d'un disque en argent de 5 mm de diamètre dont la cupule centrale permet l'application d'une pâte conductrice, elle est collée sur le crâne sur un support imbibé de collodion. Ces électrodes sont recommandées pour tout enregistrement

de longue durée et lorsque la probabilité d'enregistrement d'une crise épileptique est forte.

– **L'électrode aiguille**

A la forme d'une aiguille hypodermique en acier inoxydable ou argentée, introduite juste sous la peau, parallèlement à la surface. Ces électrodes sont à usage unique et réservées aux situations d'urgence, en réanimation, au bloc opératoire.

**Système 10-20.** Pour assurer un positionnement spatial identique selon un repère anatomique propre à chaque patient, des normes ont été élaborées en routine clinique. Ces normes dépendent de la résolution spatiale souhaitée. En ce qui concerne les travaux présentés dans ce mémoire de thèse, dix-neuf électrodes de surface, voire 21 semblent indispensables en routine. L'emplacement des électrodes est standardisé par une nomenclature internationale appelée 10 – 20 [Jasper, 1958]. Aujourd'hui avec l'amélioration des électrodes, des technologies d'enregistrement, le nombre d'électrodes peut considérablement être augmenté pour atteindre parfois 64, 128 voire 256 (EEG à "haute résolution – EEGHR"), mais toutes découlent du système 10-20. Ce système fixe de façon proportionnelle l'emplacement des électrodes par rapport à des repères osseux fixes (figure 1.14).

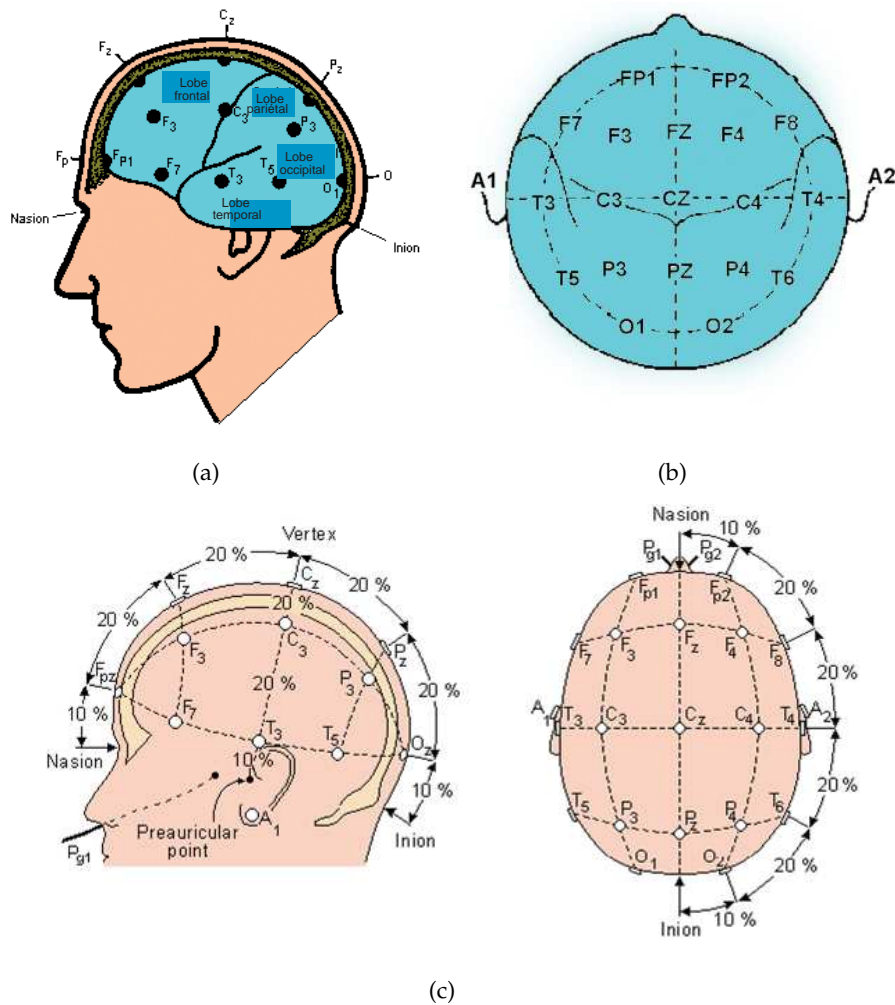
Les positions sont définies en divisant les lignes crâniennes des plans médian et transversal, en segments de 10 et 20 pour cents de leur longueur (figure 1.14(c)).

Chaque électrode porte un nom précis, les chiffres pairs de chaque électrode indiquant le côté droit, et les chiffres impairs le côté gauche. Les lettres obéissent à la logique suivante : A=lobe de l'oreille, C=central, P=pariétal, F=frontal, Fp=frontal polaire, O=occipital, T=temporal et la lettre z indique l'axe central.

**Les montages.** Un montage EEG correspond à la combinaison de couples d'électrodes. Deux types de montages principaux peuvent être utilisés : les montages référentiels et/ou les montages bipolaires. Il peut exister aussi un troisième type de montage, (moins utilisé) le montage laplacien.

**Le montage référentiel.** Dans les montages référentiels, l'enregistrement de chaque électrode est fait par rapport à une électrode de référence. En théorie, la différence de potentiel correspond à la valeur absolue du signal recueilli sous la seule électrode active. En pratique, l'électrode de référence doit être choisie pour être la plus inactive possible, mais la référence parfaitement nulle n'existe pas et il existe toujours une contamination bio-électrique cérébrale ou extra-cérébrale de la référence. Le problème du choix l'électrode





**FIGURE 1.14.** *Système de positionnement des électrodes 10 – 20 : sur cet exemple 21 électrodes sont posées*

de référence est encore un problème d'actualité [Salido-Ruiz *et al.*, 2009; Hu *et al.*, 2007; Zhai et Yao, 2004; Geselowitz, 1998; Vespignani, 1998].

Une solution usuelle en clinique est de faire appel à un deuxième type de montage référentiel, consistant à utiliser une référence virtuelle (référence moyenne). La référence est représentée par le potentiel de référence moyen défini par la moyenne des potentiels de l'ensemble. En supposant une répartition symétrique des électrodes sur la surface de la tête, les sources intra-cérébrales, modélisées comme des dipôles électriques, devraient engendrer sur la surface de la tête des potentiels de somme nulle, ce qui fait que cette référence moyenne est supposée nulle [Perrin *et al.*, 1989]. Cette méthode est particuliè-

rement intéressante quand il n'y a pas de potentiels de très grande amplitude (artéfacts oculaires) ou de potentiels diffus, dans le cas contraire la polarité risque d'être faussée par les perturbations, ce qui peut amener à des conclusions erronées (une référence moyenne perturbée par les artéfacts par exemple). De plus, en réalité la tête n'est pas entièrement couverte par des électrodes de mesure, ce qui fait que l'hypothèse de base (répartition symétrique) est très approximative et donc que le signal obtenu en moyennant les mesures (référence moyenne) n'est pas strictement nul.

**Le montage bipolaire.** Les montages bipolaires sont des connexions entre deux électrodes "actives", c'est-à-dire différentes de la référence. La différence de potentiel correspond à la somme algébrique des signaux recueillis sous chaque électrode active (ce qui conduit implicitement à l'élimination de la référence). Il y a principalement deux types de montages bipolaires : le montage bipolaire antéropostérieur (ou longitudinal) qui explore d'avant en arrière et le montage bipolaire transverse qui explore de droite à gauche.

Le montage référentiel et le montage bipolaire sont complémentaires, car ils ne s'interprètent pas de la même manière. Dans un montage référentiel, c'est l'amplitude de l'enregistrement qui renseigne sur l'activité cérébrale alors que dans un montage bipolaire, c'est plutôt l'inversion de phase qui permettra de déduire la localisation du dipôle. Le montage bipolaire représente une mesure locale de l'activité sous-jacente. Une autre différence est que les premiers sont plutôt utilisés pour le diagnostic d'une crise très focale alors que les seconds sont préférés pour des crises plus étendues.

Un enregistrement se réalise toujours sur un montage référentiel avec possibilité ultérieure de recombinaison de montages bipolaires ou référentiel moyen. Lors de la lecture du tracé, pour l'interprétation, les cliniciens choisissent le ou les montages les plus informatifs. Le choix du montage dépend de la pathologie sous-jacente et des informations suspectées à la lecture d'un premier montage. On peut ainsi comparer une même séquence (par exemple une crise épileptique) selon différents montages.

**Le montage laplacien.** Montage utilisable en EEG numérisé, consistant en une transformation mathématique utilisant la dérivée seconde spatiale. On peut approcher la valeur laplacienne du potentiel en utilisant la valeur moyenne des électrodes de voisinage comme référence, et ce pour chaque électrode [Guérit *et al.*, 2002].

**L'EEG-vidéo continu.** L'enregistrement repose sur le même principe que l'EEG standard couplé à la vidéo de façon synchronisée. L'enregistrement EEG-vidéo est effectué

de façon prolongée et continue pendant 2 à 5 jours consécutifs 24 heures sur 24 dans une chambre d'hospitalisation, afin de visualiser les manifestations électriques et cliniques de jour comme de nuit (on recueille habituellement un minimum de deux ou trois crises pour un même patient).

L'enregistrement vidéo des crises permet de mieux cerner la sémiologie critique et apporte des informations indispensables pour interpréter l'EEG. Ce type d'enregistrement est indiqué pour coupler à la mesure EEG une étude sémiologique dans le cadre d'évaluation préchirurgicale des épilepsies partielles sévères pharmacorésistantes dans la perspective d'une intervention chirurgicale.



**FIGURE 1.15.** Exemple d'enregistrement EEG-vidéo


**La Magnétoencéphalographie.** La magnétoencéphalographie (MEG) (figure 1.16) est une technique relativement récente. Ce n'est qu'en 1968 que Cohen [Cohen, 1968], un physicien spécialisé dans les blindages magnétiques, enregistra pour la première fois les champs magnétiques issus de l'activité cérébrale.

L'origine du signal MEG est directement reliée à celle de l'EEG. En effet la loi de Biot-Savart indique que chaque courant élémentaire issu de l'activité des cellules nerveuses produit un champ magnétique perpendiculaire. Il est donc possible de mesurer les variations du champ magnétique.

On enregistre essentiellement la contribution des courants intra- et extra-cellulaires dûs aux potentiels post synaptiques. Les systèmes MEG actuels possèdent de 50 à 200 capteurs permettant chacun de capturer une composante (radiale en général) du champ magnétique.

Les champs cérébraux générés sont 10 milliard de fois plus faibles que les champs magnétiques terrestres, ce qui explique la complexité de la mesure à mettre en œuvre.

La MEG est une technique très coûteuse tant à l'achat qu'à l'entretien.



**FIGURE 1.16.** *Illustration des enregistrements MEG et d'un casque MEG*

### 1.1.3.2 Les méthodes semi-invasives


La méthode semi-invasive la plus commune date de travaux de Jasper [Jasper, 1954], l'Electrocorticographie (ECoG).

**L'Electrocorticographie (ECoG).** L'ECoG est principalement utilisée dans les pays anglo-saxons. Une fenêtre de quelques dizaines de  $\text{cm}^2$  est ouverte dans le crâne et une grille contenant une matrice de capteurs est posée directement sur le cortex (figure 1.17).

Son principal avantage par rapport à l'EEG de surface est qu'elle permet de s'affranchir des transformations du signal introduites par le crâne et le cuir chevelu, par les courants surfaciques, lors du transfert du signal vers la surface. Toutefois, l'information ainsi recueillie n'est toujours qu'une projection surfacique et ne restitue que partiellement l'activité électrique des structures profondes.

### 1.1.3.3 Les méthodes invasives

La technique d'enregistrement des signaux EEG invasive la plus courante est la Stéréoelectroencéphalographie (SEEG). Elle a été développée en France par Bancaud et Talairach à la fin des années 50 [Talairach et Bancaud, 1958; Bancaud, 1959].




**FIGURE 1.17.** Matrice de capteurs placée sur le cortex

**La Stéréoélectroencéphalographie (SEEG).** La Stéréoélectroencéphalographie (SEEG) est une technique d'exploration fonctionnelle du cerveau qui enregistre l'activité électrique de certaines structures potentiellement impliquées dans les crises d'épilepsie. Associées à des enregistrements vidéo simultanés, voire à des enregistrements EEG de surface, ces données alimentent l'analyse électro-clinique des crises, dans la délimitation des sites cérébraux impliqués par les décharges paroxystiques.

Une électrode comprend entre 10 et 15 capteurs (figure 1.18). Le signal vectoriel résultant est enregistré sur 80 à 128 voies (selon les systèmes d'acquisition). En pratique, les patients sont généralement accueillis dans une unité d'épileptologie pendant 5 jours [Bourien, 2003].

L'intérêt principal de la SEEG, par rapport à l'EEG, est de recueillir l'activité électrique des neurones directement au contact des générateurs, ce qui permet d'enregistrer des signaux représentant une activité locale. La SEEG mesure donc l'activité épileptique de façon très focale avec une très bonne résolution spatiale dans l'axe du support d'électrodes. Elle donne des renseignements sur la profondeur de la zone épileptogène. Les enregistrements SEEG ont de plus l'avantage de ne pas être perturbés par la plupart des activités de surface [Adam *et al.*, 2000; Wendling, 1996]. En revanche, la nature invasive de la méthode constitue une limite importante et elle n'est appliquée que dans des cas définis très précisément par les cliniciens.



**FIGURE 1.18.** *Electrodes cylindriques avec des capteurs implantés dans le cerveau*

#### 1.1.3.4 La neuro-imagerie

La neuro-imagerie recouvre différentes techniques permettant de "voir" le cerveau, l'architecture spatio-temporelle ainsi que ses modifications lors de pathologies neurologiques et psychiatriques. Dans le cas qui nous concerne dans cette thèse, elles ont pour but de mieux délimiter le foyer épileptogène à l'origine des crises.

Dans le cadre général de la neuro-imagerie, on trouve des examens et techniques très différents, à la fois par leur principes physiques d'acquisition que par leurs objectifs précis :

- les techniques qui visent principalement à mettre en évidence des structures anatomiques, sans donner des informations directes sur leur fonctionnement, sont le scanner et l'imagerie par résonance magnétique (IRM). Dans le cas des épilepsies, ces examens cherchent à localiser des éventuelles lésions qui pourraient expliquer le déclenchement ou le déroulement des crises.
- la tomographie par émission de positons (TEP) est une technique dite d'imagerie fonctionnelle. Elle tente de mettre en évidence des zones d'hypométabolisme qui seraient en relation avec un dysfonctionnement cérébral ou des anomalies fonctionnelles en rapport avec la zone épileptogène.


**L'imagerie par résonance magnétique (IRM).** L'IRM est la méthode d'imagerie la plus récente et la plus sophistiquée. Richard Ernst a proposé le concept d'imagerie par résonance magnétique et ses bases théoriques en 1975. Au début des années 1980, l'IRM

commence à se diffuser et s'imposer en routine clinique [Kastler *et al.*, 2006].

L'IRM (figure 1.19) peut produire deux principaux types d'images de la tête et du cerveau, les images anatomiques et les images fonctionnelles. Les deux types d'images possèdent une résolution spatiale de l'ordre du millimètre (figure 1.5), le temps d'acquisition de chaque image variant de une à dix secondes.

Les images anatomiques apportent une image 3D de la densité d'eau présente. Elles permettent, après segmentation, d'obtenir des modèles 3D réalistes de la tête de chaque sujet en discernant chacun des milieux.


Les images fonctionnelles, quant à elles, permettent de représenter la concentration d'oxygène dans le sang. Elles fournissent des images 3D permettant de localiser une activité cérébrale par la consommation d'oxygène qu'elle occasionne. Cette modalité est très appréciée d'un point de vue clinique, car elle fournit des images de très bonne qualité facilitant grandement les diagnostics. Concernant l'étude du cerveau, cette technique manque d'une bonne résolution temporelle, néanmoins elle fournit la meilleure précision spatiale en termes d'imagerie fonctionnelle. Un autre inconvénient de l'IRM est qu'elle nécessite un équipement très coûteux tant à l'achat qu'à l'entretien.



**FIGURE 1.19.** *Un scanner IRM et une image IRM (coupe axiale du cerveau)*

**La Tomographie à Emission de Positons (TEP).** Cette technique consiste à injecter au patient un marqueur radioactif, c'est-à-dire émettant des positons qui sont en général incorporés dans une molécule impliquée dans le métabolisme glucidique ou de la consom-

mation en oxygène. Le marqueur, une fois injecté se répand dans la zone de l'organisme à imager. Il est alors possible de détecter le marqueur et sa concentration grâce aux émissions gamma que sa radioactivité déclenche. Dans l'imagerie neurologique pour le diagnostic des épilepsies, l'hypothèse est que le volume d'hypométabolisme est en relation avec la zone épileptogène [Semah, 2007] (même si, souvent, les deux ne se superposent pas complètement).



**FIGURE 1.20.** Un scanner TEP et une image TEP (vue axiale du cerveau)

Pour déterminer au mieux la localisation de la zone épileptogène, l'imagerie médicale apporte une information souvent utile, mais quelquefois insuffisante pour la localiser. Son utilisation dans le cadre de l'épilepsie se doit de reposer sur une cohérence entre les images apportées par les différentes techniques, les données de l'observation clinique et l'électroencéphalogramme (et/ou un autre examen électrophysiologique) des crises.

## 1.2 Objectifs et problématique

En ce qui concerne l'épilepsie, des travaux récents ont été développés avec différents objectifs. Il est impossible de tous les citer, on peut toutefois mettre en exergue certains travaux relativement récents tels que : la modélisation de sources et des synchronicités inter-structures tels les couplages neuronaux des populations de neurones [Cosandier-Rimélé *et al.*, 2008; Wendling *et al.*, 2005], la caractérisation de crises en intra- et extra-cérébral [Wendling *et al.*, 2001; Caparos, 2006; Spatt *et al.*, 1997], la localisation



de sources par la résolution de problème inverse à partir de modèles de connaissance [Gavaret *et al.*, 2009].

De façon générale, le travail présenté dans ce mémoire s'inscrit dans l'aide au diagnostic neurologique plus précisément l'épilepsie et plus particulièrement dans l'étape de prétraitement des EEG de surface. En effet, l'analyse des EEG de surface est une étape importante dans le raisonnement scientifique et clinique qui mène au diagnostic. Or les EEG de surface sont très souvent altérés par les perturbations extra-cérébrales et les perturbations électromagnétiques en général. Ces perturbations présentent des caractéristiques qui nuisent à l'interprétation. En effet, elles peuvent être très énergétiques par rapport aux signaux d'intérêt, elles sont également présentes dans les mêmes bandes spectrales.

### 1.2.1 Objectifs médicaux

Comme mentionné précédemment, l'EEG est une technique d'utilité majeure pour le diagnostic de l'épilepsie. Certaines manifestations typiques comme des ondes lentes et des pointes-ondes peuvent apparaître sur l'EEG, permettant aux neurologues de détecter une souffrance épileptique. La lecture des signaux EEG ainsi que leurs analyses et interprétations sont cruciales pour mener à un diagnostic pertinent et juste. Ce diagnostic devient d'autant plus important dans le cas des épilepsies réfractaires. Dans ce cas, l'issue thérapeutique ne peut être envisagée qu'à travers l'exérèse de la zone épileptogène. Ce qui signifie que, dans la démarche de caractérisation de la crise, il est nécessaire d'aller jusqu'à la localisation précise de la zone épileptogène. Or cette zone peut revêtir des spécificités physiologiques, anatomiques et spatiales différentes. Elle peut être superposée à une zone lésionnelle, être distante d'une zone lésionnelle, voir ne comporter aucune anomalie lésionnelle. Autrement dit, dans certain cas, l'analyse IRM n'est pas suffisante. L'étude de la sémiologie et l'analyse EEG deviennent alors les modalités exploitées pour la localisation.

L'EEG de surface représente une projection des activités régionales électrophysiologiques de profondeur. Elle manque donc de précision et de résolution spatiale dans cette dimension qui est la profondeur cérébrale. La SEEG est donc la modalité de référence pour localiser la zone épileptogène. Cependant, elle est invasive et donc traumatisante, elle nécessite une chirurgie lourde d'implantation d'électrodes, et elle oblige au préalable à une étape de prélocalisation de la zone épileptogène afin de guider et orienter le positionnement des électrodes intra-cérébrales. Il est en effet hors de question d'envisager un quadrillage cérébral complet. Cette dernière remarque renvoie donc à l'analyse EEG car

ce sont ses conclusions qui guideront l'étape d'implantation. Soit l'EEG et le type d'épilepsie sont parfaitement caractérisés et dans ce cas l'exérèse est possible, soit l'information extraite des EEG surface ne permet pas une localisation suffisamment précise de la zone épileptogène et les informations sont exploitées pour guider l'implantation d'électrodes de profondeur. Dans tous les cas, la richesse des informations spatio-temporelles extraites des EEG de scalp est extrêmement importante. Plus les perturbations seront rejetées plus l'extraction de caractéristiques pertinentes sera facilitée et de ce fait l'interprétation facilitée. La figure 1.21 illustre le fait que l'activité électrophysiologique peut être masquée par des artéfacts qui ressemblent morphologiquement à des activités paroxysmiques (pointes, pointes-ondes). L'objectif fondamental de cette thèse est donc l'identification et l'élimination d'artéfacts et des perturbations. Ceci constitue un aspect important pour la lecture et l'interprétation, à la fois lors de l'analyse visuelle, mais également lors du traitement automatique (détection et segmentation d'événements, estimation de synchronisation, latéralisation, localisation, classification) des signaux d'EEG.

### 1.2.2 Objectifs scientifiques

Cette thèse vise donc à développer une méthodologie de traitement dédiée à l'identification d'artéfacts (mouvements oculaires, clignements, activité cardiaque, musculaire) et du bruit qui perturbent la lecture, l'interprétation et l'analyse des enregistrements d'EEG (visuelle et automatique), suivi de leur élimination avec une perte minimale d'information. L'automatisation de l'identification et de l'élimination d'artéfacts permettra par la suite la reconstruction des signaux d'EEG dits "propres".


L'hypothèse de base étant que les artéfacts et les sources cérébrales ont des origines distinctes, la méthode la plus exploitée et la plus efficace pour les séparer présente dans la littérature actuellement est la Séparation Aveugle de Sources.

Les mesures EEG sont modélisées comme un mélange linéaire instantané ou convolutif de sources. Par résolution de problème inverse en exploitant un certain nombre d'hypothèses<sup>2</sup>, il est alors possible d'accéder à l'estimation du système de mélange et des sources d'origine. Le choix le plus courant est celui d'un mélange linéaire. Il est évident que ce modèle de mélange est d'ores et déjà un choix qui mérite d'être discuté, cependant il s'avère que cette approche possible de ce problème en gardant toutefois un regard critique sur les résultats qu'elle peut générer.

Sous cette hypothèse, les travaux de la littérature font état pour les plus anciens

---

2. La définition des hypothèses de travail doit conduire à la méthode d'optimisation des estimées.



**FIGURE 1.21.** Exemple d'un enregistrement EEG, pendant une crise épileptique, fortement perturbé par des artefacts

d'entre eux d'une étape d'identification et de classification de sources par inspection visuelle [Vigario, 1997; Jung *et al.*, 2000b]. La procédure est fastidieuse et sa validation subjective.

De façon générale, les méthodes d'identification automatique se concentrent sur l'identification de l'artéfact oculaire en exploitant l'électro-oculogramme (EOG) et/ou des caractéristiques temporelles, spatiales et fréquentielles des sources [Wallstrom *et al.*, 2004; Joyce *et al.*, 2004; Krishnaveni *et al.*, 2006; Li *et al.*, 2006; Nicolaou et Nasuto, 2007; Romero *et al.*, 2008]. Ces méthodes sont adaptées pour identifier les artéfacts oculaires parmi les autres sources et elles sont donc difficilement extensible à d'autres types d'artéfacts.

Plus récemment, plusieurs méthodes d'élimination automatique d'artéfacts basées sur la SAS (HOS et SOS) ont été proposées. Par exemple, Boudet *et al.*, 2007; Teixeira *et al.*, 2006 ont proposé des méthodes de séparation et d'élimination d'artéfacts intégrés,

l'objectif étant de séparer en deux sous-espaces les sources cérébrales et les sources d'artéfact.

Différentes méthodes d'élimination complète d'artéfacts ont été aussi présentées dans la littérature. James et Gibson, 2003 proposent un algorithme d'ICA sous contrainte en utilisant des signaux de référence *a priori* comme base de comparaison. L'acquisition des signaux de référence représentant les artéfacts est alors synchronisée avec les EEG. Plus récemment Greco *et al.*, 2006, Ting *et al.*, 2006 et LeVan *et al.*, 2006 proposent des méthodes basées sur l'ICA avec les algorithmes respectifs Infomax, AMUSE (SOS) et FASTICA. Les étapes de classification de sources sont basées sur des caractéristiques temporelles, fréquentielles et spatiales et sur des règles de décision (le choix des seuils est crucial pour éviter l'élimination de sources informatives) pour les deux premières méthodes et sur une analyse discriminante basée sur les règles de Bayes pour la dernière. Ces processus génèrent 2 classes : les sources d'EEG et les sources d'artéfact.

L'objectif de ce travail est de pré-traiter les signaux EEG en supprimant les artéfacts électrophysiologiques, mais également le bruit de fond. La méthode présentée dans cette thèse propose une élimination complète d'artéfacts (oculaire, de sources haute-fréquence et ECG). Cette méthodologie est basée sur la SAS (SOBI-RO) en combinaison avec des méthodes de classification : un système expert et l'analyse discriminante (basée sur la distance de Mahalanobis et le classificateur de Bayes). La classification traite des caractéristiques spatiales, temporelles et fréquentielles. Ces méthodes de classification répartissent les sources en 4 classes : oculaires, sources haute-fréquence (musculaires), ECG, et les sources dites cérébrales. Cette conception et structuration des sources présente l'avantage de permettre l'élimination d'un seul type de sources (une seule classe), partielle ou complète des artéfacts. En comparant ce développement à ceux présentés dans la littérature, notre méthode propose l'élimination complète d'artéfacts sans nécessiter d'électrodes supplémentaires. En ce qui concerne la validation, les algorithmes de séparation de sources ont, dans un premier temps, été éprouvés sur des signaux simulés (sources et matrice de mélange). La composition fonctionnelle SAS et la classification appliquées aux signaux réels a bénéficié d'une validation par expertise médicale. Dans un second temps, nous avons proposé d'évaluer le bénéfice que pourraient apporter à ces méthodes l'introduction d'une étape de débruitage dans la procédure de pré-traitement. Cette combinaison de techniques de type séparation de sources, classification supervisée et débruitage nécessite bien évidemment une validation à chaque étape de traitement pour définir le choix des algorithmes et de leurs paramètres. La mise en place d'une méthodologie intégrant (d'une manière optimale) ces trois techniques (séparation de sources, classification

supervisée et débruitage par ondelettes) constitue l'apport principal de cette thèse.

### 1.2.3 Problématique

Le travail présenté dans cette thèse cherche à explorer les différents schémas de traitement du signal possibles intégrant les trois méthodes énumérées précédemment et vise à choisir la meilleure chaîne de traitement pour l'élimination des artefacts et du bruit dans les signaux EEG de surface. Cette optimisation sera faite à la fois en terme de fonctions individuelles (meilleurs algorithmes de chaque domaine) et en terme de structure et d'ordonnement (ordre des étapes de traitement).

Les différentes constituantes de la chaîne de traitement résultante, ainsi que leur combinaison, nécessitent le développement d'une méthodologie de validation, focalisée d'un côté sur les méthodes de traitement individuelles et d'un autre côté sur les résultats globaux, surtout en termes d'exploration médicale. Cette validation peut être effectuée sur des signaux simulés. L'exercice devient beaucoup plus périlleux pour évaluer ce traitement sur des signaux réels : la validation est élaborée à partir de l'expertise médicale. Une collaboration très forte avec les neurologues est donc absolument indispensable. Enfin, nous présentons dans ce mémoire une évaluation objective du pré-traitement appliqué sur une base de données d'EEG contenant des crises d'épilepsie expertisées. À travers l'évolution des performances fournies par des méthodes automatiques de type détection et/ou latéralisation automatique, il est possible de mesurer l'influence du pré-traitement.

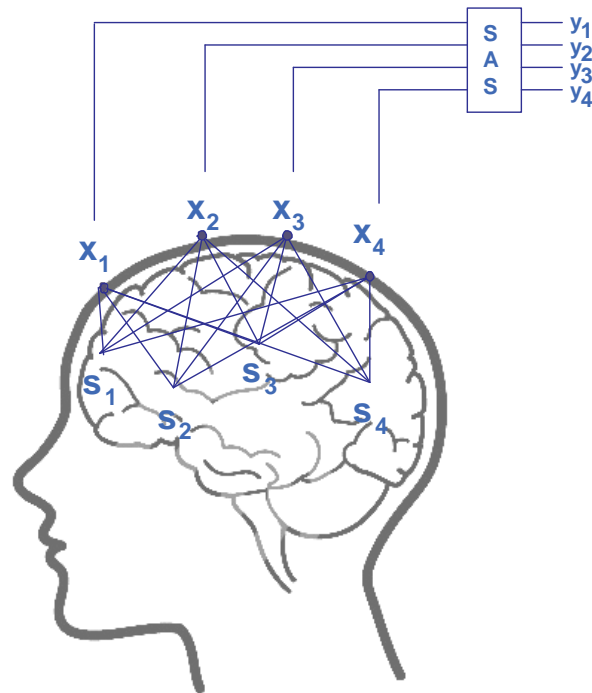
Nous présentons par la suite brièvement la problématique spécifique de chacune des trois méthodes de traitement du signal et de leur utilisation jointe.

#### 1.2.3.1 Séparation de sources

L'activité cérébrale est recueillie par les capteurs ( $\mathbf{x}$ ) positionnés sur le cuir chevelu. Les signaux enregistrés par l'EEG sont un mélange des différentes sources ( $\mathbf{s}$ ) (sources d'activité cérébrale et sources d'artefacts supposées indépendantes (figure 1.22)).

La méthode utilisée pour l'identification de sources d'artefacts est la séparation aveugle de sources (SAS - *BSS blind source separation*), qui vise à extraire des sources indépendantes à partir de signaux mesurés.

La séparation aveugle de sources (SAS) désigne une famille de méthodes d'analyse statistique consistant à estimer les sources inconnues  $\mathbf{s}$ , supposées d'origines indépendantes, à partir des mélanges inconnus (EEG) de ces sources, avec très peu de connaissances *a priori* sur les sources ou les caractéristiques du mélange. Ce type de méthode a



**FIGURE 1.22.** *Modèle de mélange de sources et sources trouvées après la SAS*

été mis en œuvre avec succès pour l'élimination d'artéfacts des signaux électroencéphalographiques par plusieurs équipes [Vigario, 1997; Delorme *et al.*, 2001; Jung *et al.*, 2000b]. Néanmoins, aucun consensus n'existe actuellement sur la méthode de SAS la plus adaptée pour les signaux EEG de surface. Un premier objectif est de comparer les méthodes proposées dans la littérature et de déterminer la méthode la plus adaptée pour notre application. Cette étape de comparaison doit nécessairement passer par la simulation des sources et du mélange.

### 1.2.3.2 Identification et élimination automatique d'artéfacts

Actuellement, dans la plupart des cas, l'identification des séquences d'EEG contaminées par des artéfacts est réalisée visuellement par les experts. Cette sélection manuelle des séquences contenant des artéfacts sert à leur élimination ultérieure dans les étapes d'analyse ou d'interprétation, ce qui implique une perte d'information. Comme pour l'identification de ces séquences, la ou les sources d'artéfacts peuvent être identifiées visuellement, après séparation, par les experts cliniques. L'intérêt d'une telle procédure contrairement à la détection et segmentation d'artéfacts est de conserver toute la série temporelle de l'enregistrement, sans exclure les parties contaminées : cette remarque est

d'autant plus intéressante lorsque la procédure est appliquée aux "patterns" épileptogène et à sa phase pré-critique proche car ces enregistrements sont soumis, dans la plupart des cas, à de fortes perturbations.

Néanmoins, deux problèmes apparaissent :

- L'identification de ces sources n'est pas toujours évidente, car elles ne sont jamais enregistrées individuellement, c'est-à-dire en dehors d'un mélange avec les sources d'activité cérébrale. En pratique, l'identification visuelle de ces sources d'artéfacts se fait en comparant les tracés EEG classiques avec les sources séparées : si un événement reconnu comme un artéfact sur les mesures EEG de surface est synchrone et présente une morphologie similaire à un événement présent sur une source, et si cette source ne contient pas, par ailleurs, une activité cérébrale visible, elle sera désignée comme source d'artéfacts et éliminée.
- L'identification visuelle reste toutefois subjective et longue : il n'y a pas toujours consensus d'expertise dans l'évaluation de plusieurs experts ; de plus, un même expert peut avoir une appréciation différente au cours du temps, en fonction surtout de l'objectif médical qu'il poursuit. Typiquement, lors d'une crise d'épilepsie, l'expert aura tendance à sélectionner les sources d'intérêt (donc, il choisira les sources utiles pour la reconstruction d'un EEG qui facilite l'interprétation de la crise épileptique), alors que dans une période inter-critique, il sera enclin à sélectionner les sources de perturbation (autrement dit, les sources à éliminer avant reconstruction, afin d'avoir une représentation plus claire de cette activité et de déceler, si possible, des signes épileptiques cachés dans l'activité normale).

Pour ces raisons, il est donc intéressant d'utiliser un procédé d'identification et de classification automatique de sources. La subjectivité est réduite et le système peut être adapté en fonction de l'objectif médical : aucune perte d'information (donc une élimination limitée aux artéfacts les plus énergétiques), ou alors préservation de l'information pertinente uniquement. Cependant, une méthode de classification est basée sur les connaissances injectées par les experts, donc les méthodes automatiques sont de type classification supervisée. Trois méthodes de classification sont envisagées : un système expert construit et formalisé à partir des connaissances médicales, et deux types d'analyse discriminante (la distance de Mahalanobis et le classificateur de Bayes – analyse quadratique).

Les performances d'un tel système automatique dépendent d'une manière importante de l'étape d'apprentissage et des caractéristiques choisies pour décrire les sources. Ces étapes, préalables à la classification automatique, sont elles aussi basées sur l'exper-

tise médicale, et la formalisation de cette expertise, ainsi qu'une analyse de ses limites, constituent un des problèmes importants qui seront traités dans cette thèse.

### 1.2.3.3 Débruitage par ondelettes

Les enregistrements EEG de surface sont des signaux non stationnaires, car issus de processus différents et évoluant dans le temps en fonction de l'activité cérébrale et extra-cérébrale artéfactuelle). Les mesures sont de plus bruitées, chaque électrode étant en principe affectée par un bruit de mesure additif. Une solution désormais classique dans ce contexte pour l'élimination du bruit est le débruitage par ondelettes.

La décomposition en ondelettes est une méthode qui offre également des informations sur les caractéristiques temporelles et fréquentielles d'un signal. Le principe de base du débruitage est que, lors de la décomposition d'un signal bruité sur une base d'ondelettes orthogonales, la partie informative est concentrée en un nombre réduit de coefficients de grande valeur, alors que le bruit peu corrélé avec les ondelettes de la décomposition est réparti sur l'ensemble des coefficients de la décomposition. Par conséquent, on peut utiliser un seuillage pour supprimer ces coefficients et conserver les coefficients d'ondelettes importants. La problématique consiste à définir le seuil. Plusieurs méthodes d'évaluation du seuil existent, et le choix du meilleur algorithme pour notre application constitue un des aspects de ce travail.

### 1.2.3.4 Chaîne de traitement

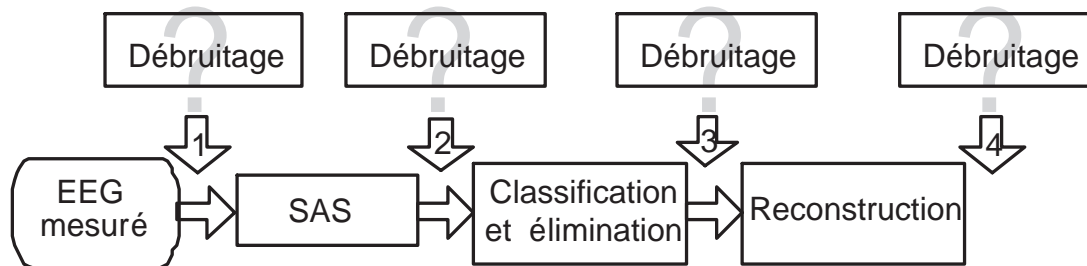
Enfin, un point très important est l'ordonnancement fonctionnel. Évidemment, la classification des sources doit être implantée après la séparation. Par conséquent, la combinaison des méthodes de SAS, débruitage et classification peut être implantée de quatre manières différentes :

1. Débruitage de l'EEG mesuré  $\Rightarrow$  séparation  $\Rightarrow$  classification et élimination  $\Rightarrow$  reconstruction de l'EEG
2. Séparation de l'EEG mesuré  $\Rightarrow$  débruitage  $\Rightarrow$  classification et élimination  $\Rightarrow$  reconstruction de l'EEG
3. Séparation de l'EEG mesuré  $\Rightarrow$  classification et élimination  $\Rightarrow$  débruitage  $\Rightarrow$  reconstruction de l'EEG
4. Séparation de l'EEG mesuré  $\Rightarrow$  classification et élimination  $\Rightarrow$  reconstruction de l'EEG  $\Rightarrow$  débruitage



L'analyse et le choix parmi ces différentes chaînes de traitement possibles permet d'atteindre l'objectif final de cette thèse – la conception d'une méthodologie de pré-traitement des EEG de surface visant à éliminer ou à diminuer les perturbations (artéfacts et bruit) qui gênent l'interprétation médicale et les méthodes d'analyse automatique.

La figure 4.1 illustre les possibles chaînes de traitement proposées.



**FIGURE 1.23.** Méthodologie proposée pour l'identification et l'élimination des artéfacts et l'élimination du bruit

### 1.3 Plan de la thèse

Notre travail de thèse comporte cinq chapitres.

Le premier chapitre a été consacré au contexte de la recherche en précisant d'abord le contexte médical de ce travail, les objectifs et finalement la problématique scientifique.

Dans les chapitres suivants, nous présentons les méthodes de traitement du signal qui constituent la chaîne de pré-traitement que nous proposons.

Le deuxième chapitre est consacré à la séparation de sources. Nous présentons les applications de cette famille de méthodes en EEG, ainsi que les principaux aspects théoriques. Nous justifions les choix que nous faisons à la fois en fonction de l'étude bibliographique présentée et à travers des comparaisons quantitatives entre les différents algorithmes, en utilisant des signaux EEG simulés.

Le troisième chapitre présente les implémentations possibles de la classification de sources. Après l'extraction des caractéristiques et la construction d'un ensemble d'apprentissage, nous comparons trois méthodes de classification supervisée à l'aide de plusieurs indices de performance comme la sensibilité et la spécificité des classifieurs, mais aussi en s'appuyant sur une validation médicale détaillée.

Le quatrième chapitre se focalise sur le problème du bruit additif. Après une brève

présentation des méthodes de débruitage par ondelettes, nous analysons les conséquences de l'introduction du débruitage sur les performances des méthodes de séparation et de classification, et donc finalement sur le résultat final de la chaîne de traitement.

Enfin, le cinquième chapitre présente quelques exemples d'application clinique de la méthodologie proposée et validée précédemment : est-elle adaptée aux EEG de longue durée, contenant des signaux épileptiques ? Nous analysons les résultats obtenus avec la chaîne de traitement proposée sur les signaux de crise et nous présentons les résultats de la validation médicale. Par la suite, nous proposons une amélioration possible de l'étape de classification. Enfin, nous nous intéressons à l'implémentation du pré-traitement proposé avant l'analyse de synchronicité, et aux résultats de cette analyse, avec ou sans pré-traitement, dans la caractérisation du déroulement des crises épileptiques.

Une conclusion mettant en avant les contributions et les perspectives du travail achève ce document.

Par ailleurs, nous présentons en annexe A les figures, représentant les EEG réels obtenus après application de la méthodologie de prétraitement. Ces figures sont au format A4 pour une meilleure visualisation.



## Chapitre 2

# Séparation de sources

Le domaine de la séparation aveugle de sources (SAS) est relativement nouveau en traitement du signal. Il a été initié par C. Jutten, J. Héroult et B. Ans dans les années 80 [Héroult et Ans, 1984; Ans *et al.*, 1985]. Ces derniers ont développé, à partir d'un problème de décodage du mouvement en neurobiologie, un algorithme de séparation à base d'un réseau neuromimétique [Héroult *et al.*, 1985; Jutten et Héroult, 1991]. Par la suite, plusieurs algorithmes de SAS ont été proposés [Comon, 1991; Cardoso et Souloumiac, 1993; Comon, 1994; Bell et Sejnowski, 1995; Belouchrani *et al.*, 1997; Hyvärinen et Oja, 1997; Choi et Cichocki, 2000].

Du point de vue formel, la séparation aveugle de sources consiste à estimer  $P$  signaux inconnus  $s$  (les sources) d'après la seule connaissance de  $Q$  mélanges de signaux  $x$  (les observations). Le terme aveugle signifie que les sources ne sont pas observées et que l'on ne connaît pas le modèle de mélange  $A$  (figure 2.1).



**FIGURE 2.1.** *Modèle de la SAS*

La séparation aveugle de sources est une technique qui a de nombreuses applications, dans des domaines aussi divers que le bio-médical, les télécommunications, l'acoustique, l'exploration sismographique, la géophysique, l'analyse des signaux, etc. Parmi les applications les plus représentatives on trouve le traitement des signaux bio-médicaux [Kachenoura, 2006; Deville, 2003]. Les différentes applications visent principalement à séparer les signaux de l'électroencéphalogramme (EEG) [Jung *et al.*, 2000a], de l'électrocardiogramme (ECG) [Lathauwer *et al.*, 2000; Bacharakis *et al.*, 1996], du magnétoen-

céphalogramme (MEG) [Vigário *et al.*, 1998] et de l'électromyogramme (EMG) [Farina *et al.*, 2004; García *et al.*, 2003]. Dans ce domaine, la SAS présente aussi un intérêt pour l'analyse d'images bio-médicales, particulièrement en images IRMf [Duann *et al.*, 2002; Esposito *et al.*, 2005].

## 2.1 SAS pour l'identification des artéfacts en EEG

Parmi les applications bio-médicales, le traitement des EEG est un domaine privilégié de la séparation de sources. Une discussion détaillée sur l'application de la SAS en EEG fait l'objet de [Congedo *et al.*, 2008], et seul un résumé sera présenté ici. Le modèle général (figure 2.1) est clairement adapté pour formaliser la propagation des sources intra- et extra-cérébrales entre leur lieu de génération et les électrodes de mesure sur le scalp. Néanmoins, il n'est pas certain que les hypothèses sur les sources énoncées précédemment s'appliquent : par exemple, les modèles biologiques (bio-physiques) pour les sources cérébrales (voir chapitre 1) ne garantissent pas l'indépendance des sources cérébrales. De plus, certains modèles, en particulier dans le cas des réseaux épileptogènes, supposent explicitement une synchronisation entre les structures neuronales et donc potentiellement entre les sources. Cependant, il est largement accepté que les artéfacts extra-cérébraux sont générés indépendamment de l'activité cérébrale, donc que le modèle de séparation est applicable.

En fait, l'application principale de la séparation de sources en électroencéphalographie est l'élimination des artéfacts. Cependant, si l'objectif annoncé est le même, les différents auteurs ne modélisent pas le problème de la même manière et donc n'utilisent pas la même méthode de séparation. De ce fait, il n'y a aucun consensus dans la littérature sur l'algorithme le plus adapté pour cette application, ni d'ailleurs sur une famille d'algorithmes.

La séparation aveugle de sources couvre un nombre important de méthodes qui peuvent être très différentes, selon les caractéristiques et les hypothèses du modèle de mélange et des sources.

### 2.1.1 Les types de mélange

Le mélange le plus simple est le mélange linéaire instantané : à chaque instant, les observations sont des combinaisons linéaires des sources au même instant. Dans ce cas, le modèle du mélange est une matrice de mélange  $\mathbf{A}$  de dimension  $Q \times P$ .

En réalité, les mélanges sont souvent convolutifs : à chaque instant les observations dépendent aussi des valeurs des signaux sources aux instants précédents [Nguyen-Thi et Jutten, 1995; Boumaraf *et al.*, 2005]. Enfin, dans la littérature, on rencontre aussi des mélanges non linéaires [Taleb et Jutten, 1999; Erikson et Koivunen, 2002].

Dans le cadre du traitement des signaux électrophysiologiques de surface, il s'avère que les signaux recueillis en surface peuvent être modélisés comme un mélange de sources d'origine cérébrale et non cérébrale.

Pour ces travaux, nous nous sommes principalement intéressés à la séparation de mélanges linéaires instantanés. Puisqu'on suppose que les diverses sources (d'origine cérébrale et non cérébrale) sont additionnées par la conduction neuronale et récupérées par l'EEG de surface, on peut supposer que chaque  $\mathbf{x}(k)$  est un mélange linéaire instantané de  $P$  sources inconnues, par l'intermédiaire de la matrice de mélange inconnue  $\mathbf{A}$  (figure 2.2). Ce modèle de mélange instantané est largement adopté dans la littérature pour les signaux d'EEG [Sanei et Chambers, 2007; Congedo *et al.*, 2008].

Le modèle spatial de mélange à l'instant  $k$  est donné par :

$$\mathbf{x}(k) = \mathbf{A}\mathbf{s}(k) + \mathbf{n}(k) = \mathbf{c}(k) + \mathbf{n}(k) \quad (2.1)$$

où

$\mathbf{x}(k) = [x_1(k), \dots, x_Q(k)]^T$  vecteur des signaux observés (électrodes)

$\mathbf{s}(k) = [s_1(k), \dots, s_P(k)]^T$  vecteur des sources d'origine (inconnues)

$\mathbf{n}(k) = [n_1(k), \dots, n_Q(k)]^T$  vecteur du bruit additif, supposé indépendant

$\mathbf{c}(k) = [c_1(k), \dots, c_Q(k)]^T$  vecteur des signaux mélangés sans bruit

$\mathbf{A}(Q \times P)$  matrice de mélange (inconnue)

Sans aucune connaissance (ou hypothèse) *a priori*, le problème de séparation de sources est évidemment insoluble : les caractéristiques des signaux observés dépendent à la fois des sources inconnues et du mélange, lui aussi inconnu. L'hypothèse la plus courante (et la plus naturelle) est que, même si les signaux observés sont plus ou moins similaires, les sources sous-jacentes proviennent de phénomènes physiques distincts.

### 2.1.2 Familles d'algorithmes

Pour estimer les sources, différentes approches ont été proposées en partant des hypothèses *a priori* sur les caractéristiques des sources. Les algorithmes de SAS peuvent être regroupés selon ces hypothèses en trois principales familles :

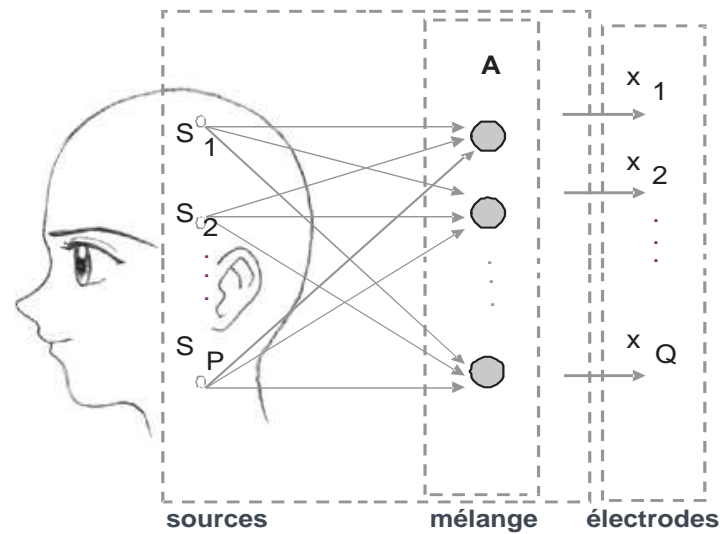


FIGURE 2.2. Représentation du modèle de mélange des signaux EEG

- **Un premier type d'hypothèses très courantes est l'indépendance statistique des sources stationnaires.** Dans ce cas, la solution est la décorrélation des signaux suivie d'une maximisation de leur indépendance statistique, estimée en supposant les signaux stationnaires. Cette analyse en composantes indépendantes (ICA - *Independent Component Analysis*) cherche à trouver des estimations des sources inconnues en les assimilant à des signaux ayant une indépendance maximale. En général, les algorithmes consistent en 2 étapes : la décorrélation suivie d'une maximisation de l'indépendance à travers la statistique d'ordre supérieur (HOS - *Higher Order Statistics*).
- **Un deuxième type d'hypothèses suppose des sources décorrélées et stationnaires par fenêtres.** La solution pour ce type de sources est la décorrélation simultanée pour toutes les fenêtres. En pratique, cette décorrélation est réalisée par la diagonalisation simultanée des différentes matrices de corrélation. Pour cette solution, la statistique d'ordre deux (SOS - *Second Order Statistics*) est suffisante.
- **Un dernier type d'hypothèses suppose des sources stationnaires, autocorrélées et décorrélées quel que soit le décalage.** La solution s'appuyant sur cette hypothèse est la décorrélation simultanée des signaux pour différents décalages et donc la diagonalisation simultanée des différentes matrices d'auto-corrélation. Donc la statistique d'ordre deux (SOS) est également suffisante pour cette solution.

Plusieurs méthodes de type ICA (voir ci-dessous pour une présentation plus détaillée), basées donc sur la statistique d'ordre supérieur (HOS), ont été appliquées et cer-

taines sont intégrées dans des toolbox Matlab largement utilisés dans la communauté scientifique (EEGLab [Delorme et Makeig, 2004]). Des versions de l'algorithme Infomax [Bell et Sejnowski, 1995] ont été appliquées en particulier pour séparer les sources d'artéfacts oculaires [Li *et al.*, 2006] ou afin de trouver toutes les sources d'artéfacts [Delorme *et al.*, 2001; Greco *et al.*, 2006]. Un autre algorithme HOS très populaire est FastICA, appliqué par exemple par [LeVan *et al.*, 2006] pour séparer toutes les sources d'artéfacts lors des crises d'épilepsie. D'autres auteurs proposent des algorithmes type JADE [Krishnaveni *et al.*, 2006] ou encore des algorithmes contraints, si l'on dispose de certains signaux de référence connus *a priori* (l'électro-oculogramme EOG et l'électrocardiogramme ECG) [James et Gibson, 2003].

Cependant, des méthodes basées sur des hypothèses plus restrictives (mais réalistes) permettent l'utilisation de la statistique d'ordre 2 uniquement. En effet, si les sources ont une structure temporelle (auto-corrélation non-nulle, autrement dit elles ne sont pas de séquences aléatoires iid), les algorithmes SOS sont suffisants. Ce point de vue est argumenté par [Congedo *et al.*, 2008] et adopté par plusieurs équipes : l'algorithme AMUSE [Tong *et al.*, 1991] est utilisé pour séparer les sources d'artéfacts par [Ting *et al.*, 2006] et le TDSEP [Ziehe et Müller, 1998] est utilisé par [Nicolaou et Nasuto, 2007]. Un des algorithmes les plus employés sur les signaux EEG est SOBI [Belouchrani *et al.*, 1993; Belouchrani *et al.*, 1997], utilisé soit pour identifier les sources d'artéfacts oculaires uniquement par [Kierkels *et al.*, 2006], ou alors pour une séparation et identification de tous les types d'artéfacts [Joyce *et al.*, 2004; Romero *et al.*, 2008].

### 2.1.3 Limites de la séparation de sources

Selon les hypothèses faites sur les sources et sous l'hypothèse d'un mélange linéaire instantané (équation 2.1), une approche possible pour traiter le problème de séparation consiste à trouver une transformation linéaire des signaux mesurés telle que les sources estimées soient le plus proche possible des sources d'origine.

L'objectif commun des différents algorithmes (HOS et SOS) est l'estimation d'une matrice de séparation  $\mathbf{B}$ , qui permette l'estimation des sources  $\mathbf{s}$  à partir des mesures  $\mathbf{x}$ , ou des signaux sans bruit  $\mathbf{c}$  :

$$\mathbf{y}(k) = \mathbf{Bc}(k) = \mathbf{BAs}(k) \quad (2.2)$$

où  $\mathbf{B}(P \times Q)$  est la matrice de séparation et  $\mathbf{y}(k) = [y_1(k), \dots, y_Q(k)]^T$  le vecteur de sources estimées.



Les sources  $\mathbf{y}$  sont exactement reconstruites quand  $\mathbf{B}$  est l'inverse (pseudo-inverse à gauche si  $P \neq Q$ ) de  $\mathbf{A}$ . Cependant, l'inverse exacte de la matrice  $\mathbf{A}$  est, en théorie, impossible à obtenir.

Cette impossibilité est mise en évidence par le raisonnement suivant : considérons le mélange  $\mathbf{c}$  (sans bruit) :

$$\mathbf{c} = \mathbf{A}\mathbf{s} \quad (2.3)$$

En multipliant les sources par une matrice diagonale de normalisation, on obtient les sources normalisées  $\mathbf{s}_n$  (écart type  $\sigma = 1$ )  $\mathbf{s}_n = \mathbf{D}_\sigma^{-1}\mathbf{s}$  où  $\mathbf{D}_\sigma$  est la matrice diagonale des écarts-types. De plus, on peut également considérer une matrice de mélange normalisée  $\mathbf{A}_n = \mathbf{A}\mathbf{D}_\sigma$ .

Dans ce cas,

$$\mathbf{c} = \mathbf{A}_n\mathbf{s}_n = \mathbf{A}\mathbf{s} \quad (2.4)$$

Autrement dit, les amplitudes des sources ne peuvent pas être connues uniquement à partir des signaux mélanges, car les coefficients de normalisation ou de gain peuvent très bien être déterminés par la matrice de mélange.

De plus, les sources (normalisées) peuvent être permutées :  $\mathbf{s}_{np} = \mathbf{P}\mathbf{s}_n$  où  $\mathbf{P}$  est une matrice de permutation. La matrice normalisée peut également être permutée  $\mathbf{A}_{np} = \mathbf{A}_n\mathbf{P}^{-1}$ . Donc si les sources et la matrice de séparation sont normalisées et permutées nous avons le mélange  $\mathbf{c}$  comme :

$$\mathbf{c} = \mathbf{A}_{np}\mathbf{s}_{np} = \mathbf{A}\mathbf{s} \quad (2.5)$$

La matrice de séparation  $\mathbf{B}$  pourrait donc être  $\mathbf{A}^{-1}$ ,  $\mathbf{A}_n^{-1}$ ,  $\mathbf{A}_{np}^{-1}$ , sans aucun moyen de le déterminer.

En conséquence, les sources peuvent être estimées, à l'exception de leur ordre (permutation) et de leur amplitude. Cette remarque étant établie, les algorithmes de séparation de sources tentent d'estimer une matrice  $\mathbf{B}$  telle que le produit  $\mathbf{G} = \mathbf{B}\mathbf{A}$  soit une matrice diagonale.

$$\mathbf{G} = \mathbf{P}\mathbf{D} = \mathbf{B}\mathbf{A} \quad (2.6)$$

où  $\mathbf{P}$  est une matrice de permutation et  $\mathbf{D}$  une matrice diagonale.

Les deux matrices  $\mathbf{P}$  et  $\mathbf{D}$  définissent la matrice de performance  $\mathbf{G}$ , donc si  $\mathbf{G}$  est la matrice identité, on a une séparation parfaite.

Une conséquence de cette indétermination fondamentale est la possibilité de faire une hypothèse assez forte sur les sources : on les considère de variance unité (sources normalisées), puisque leur amplitude est indéterminée.

#### 2.1.4 Estimation de la matrice de séparation

L'estimation de la matrice de séparation  $\mathbf{B}$ , dans la plupart des algorithmes de SAS, est effectuée en deux étapes.

Au cours de la première étape, une décorrélation des observations est réalisée avec l'estimation d'une matrice de blanchiment spatial  $\mathbf{W}$ .

La seconde étape est dédiée à l'estimation d'une transformation orthogonale  $\mathbf{J}$  (matrice de rotation). La matrice  $\mathbf{J}$  est estimée en minimisant des fonctions coût exprimées soit en utilisant HOS soit SOS.

Nous présentons d'abord l'étape de blanchiment puis la description des approches basées sur HOS et SOS. Les méthodes de SAS basées sur l'approche HOS sont présentées de manière globale et les méthodes basées sur SOS sont développées plus en détail. En effet, ces dernières constituent une partie substantielle de notre travail : puisque les signaux d'EEG sont fortement non stationnaires et avec une structure temporelle cohérente [Congedo *et al.*, 2008], ces algorithmes semblent bien adaptés [Joyce *et al.*, 2004; Kierkels *et al.*, 2006; Romero *et al.*, 2008].

De toute manière, dans les deux cas (estimation de la matrice par des méthodes HOS ou SOS) il est nécessaire de disposer d'un nombre minimal d'échantillons d'EEG mesuré (une fenêtre de longueur minimale). Selon [Delorme et Makeig, 2004] le nombre d'échantillons nécessaires pour obtenir une estimation fiable de la matrice de mélange (ou de séparation) correspond à un multiple du carré du nombre de voies de mesure  $Q$ . Différents auteurs proposent des fenêtres allant de  $5 \times Q^2$  à  $30 \times Q^2$ . En principe moins de points sont nécessaires pour les algorithmes basés sur des statistiques d'ordre deux (SOS) que pour les algorithmes basés sur l'approche HOS [Särelä et Vigarío, 2003; Gómez-Herrero *et al.*, 2005; Onton et Makeig, 2006; Delorme et Makeig, 2009; Joyce *et al.*, 2004].

##### 2.1.4.1 Blanchiment (décorrélation)

On peut considérer que la première étape vers la séparation est la décorrélation et la plupart des algorithmes de séparation proposent un prétraitement des signaux pour l'obtenir.

Le blanchiment de  $\mathbf{x}$  consiste en la décorrélation et la normalisation de ses composantes. L'idée est de trouver une matrice  $\mathbf{W}$  dite de blanchiment :

$$\mathbf{z} = \mathbf{W}\mathbf{x} \quad (2.7)$$

telle que la matrice de corrélation de  $\mathbf{z}$ ,  $\mathbf{R}_z = \mathbb{E}\{\mathbf{z}\mathbf{z}^T\}$  soit diagonale. Comme on a considéré des sources de variance unitaire, cette matrice sera égale à la matrice identité :  $\mathbf{R}_z = \mathbf{I}$ .

Une première méthode consiste à calculer la matrice  $\mathbf{R}_z$  à partir de la matrice de variance-covariance des observations  $\mathbf{R}_x = \mathbb{E}\{\mathbf{x}\mathbf{x}^T\}$ .

On peut effectuer la décomposition de  $\mathbf{R}_x$  en ses valeurs/vecteurs propres (EVD),  $\mathbf{R}_x = \mathbf{V}\Sigma_e\mathbf{V}^T$ .

Donc

$$\mathbf{R}_z = \mathbf{W}\mathbf{V}\Sigma_e\mathbf{V}^T\mathbf{W}^T \quad (2.8)$$

où  $\mathbf{V}$  est une matrice orthogonale des vecteurs propres et  $\Sigma_e$  la matrice diagonale des valeurs propres.

Pour obtenir une matrice  $\mathbf{R}_z$  égale à  $\mathbf{I}$ , une solution pour la matrice de blanchiment  $\mathbf{W}$  est :

$$\mathbf{W} = \Sigma_e^{-1/2}\mathbf{V}^T \quad (2.9)$$

Une approche équivalente est d'effectuer la décomposition en valeurs singulières (SVD) directement sur la matrice de signaux observés  $\mathbf{X}$  (ce qui revient à estimer la matrice de covariance  $\mathbf{R}_x$  à partir des observations).

On peut faire ici une observation très importante. Comme, par hypothèse,  $\mathbf{R}_s = \mathbf{I}$ ,

$$\mathbf{R}_x = \mathbb{E}\{\mathbf{x}\mathbf{x}^T\} = \mathbf{A}\mathbb{E}\{\mathbf{s}\mathbf{s}^T\}\mathbf{A}^T = \mathbf{A}\mathbf{R}_s\mathbf{A}^T \quad (2.10)$$

On peut écrire

$$\mathbf{R}_z = \mathbf{W}\mathbf{R}_x\mathbf{W}^T = \mathbf{W}\mathbf{A}\mathbf{R}_s\mathbf{A}^T\mathbf{W}^T = \mathbf{W}\mathbf{A}\mathbf{A}^T\mathbf{W}^T = \mathbf{W}\mathbf{A}(\mathbf{W}\mathbf{A})^T = \mathbf{I} \quad (2.11)$$

Autrement dit, si les sources sont blanchies, le produit  $\mathbf{W}\mathbf{A}$  est une matrice orthogonale. Si l'on veut obtenir des sources estimées  $\mathbf{y}$  indépendantes et donc décorrélées, on doit avoir également,  $\mathbf{R}_y = \mathbf{I}$ . Mais ces sources sont obtenues par une deuxième transformation  $\mathbf{J}$  à partir des signaux blanchis :

$$\mathbf{y} = \mathbf{J}\mathbf{z} = \mathbf{J}\mathbf{W}\mathbf{x} = \mathbf{J}\mathbf{W}\mathbf{A}\mathbf{s} \quad (2.12)$$




FIGURE 2.3. Exemple de blanchiment

En suivant le même développement que ci-dessus,

$$\mathbf{R}_y = \mathbf{J}\mathbf{W}\mathbf{A}\mathbf{R}_s\mathbf{A}^T\mathbf{W}^T\mathbf{J}^T = \mathbf{J}\mathbf{W}\mathbf{A}(\mathbf{W}\mathbf{A})^T\mathbf{J}^T = \mathbf{J}\mathbf{J}^T = \mathbf{I} \quad (2.13)$$

donc  $\mathbf{J}$  est aussi une matrice orthogonale.

La matrice de séparation  $\mathbf{B}$  s'écrit donc  $\mathbf{B}=\mathbf{J}\mathbf{W}$ , avec  $\mathbf{W}$  estimé par l'équation (2.9) et avec  $\mathbf{J}$  une matrice orthogonale. Ce raisonnement impose donc une forme particulière pour la transformation  $\mathbf{J}$  qui reste à estimer : elle doit être une matrice de rotation.

Un exemple est présenté dans la figure 2.3 : à partir des sources indépendantes  $\mathbf{s}$  (distribution uniforme) on obtient le mélange  $\mathbf{x}$  puis les signaux blanchis  $\mathbf{z}$ . En comparant la figure de signaux blanchis  $\mathbf{z}$  et la figure de sources  $\mathbf{s}$  on observe qu'il y a une rotation des sources  $\mathbf{s}$  et l'objectif est de trouver la rotation inverse  $\mathbf{J}^T$ .

Deux types d'approches sont présentées dans la littérature pour calculer la matrice de rotation  $\mathbf{J}$  :

- des méthodes qui cherchent à trouver la transformation qui maximise l'indépendance statistique des sources estimées (et qui sont donc basées sur des mesures d'indépendance à l'aide de HOS).

- des méthodes qui s’appuient sur la décorrélation (donc SOS), mais pas uniquement une décorrélation globale, mais plusieurs décorrélations par fenêtre ou par décalage temporel.

#### 2.1.4.2 Séparation de sources par statistique d’ordre supérieur – Analyse en Composantes Indépendantes

En utilisant des statistiques d’ordre supérieur à deux, on exploite l’indépendance statistique (au sens strict) des sources. On obtient des critères permettant de réaliser la séparation sans information supplémentaire. Ceci conduit au concept d’Analyse en Composantes Indépendantes (ACI).

Plusieurs approches utilisant l’indépendance statistique ont été développées. Ces approches sont formulées de diverses manières : en utilisant le maximum de vraisemblance, des fonctions de contraste ou un critère quadratique [Cardoso, 1998; Comon, 1991; Comon, 1994; Achard *et al.*, 2003] (voir aussi [Cichocki et Amari, 2002; Lee, 1998; Haykin, 2000]).

La divergence de Kullback-Leibler et l’information mutuelle peuvent apporter un éclairage global sur les nombreux algorithmes d’ACI existants [Jutten et Gribonval, 2003].

**Divergence de Kullback-Leibler.** Soit  $p_1(y_1)$  et  $p_2(y_2)$  deux densités de probabilités de deux composantes de  $\mathbf{y}$ . La divergence de Kullback-Leibler est définie par :

$$D(p_1|p_2) = \int_{-\infty}^{+\infty} p_1(y_1) \log \left( \frac{p_1(y_1)}{p_2(y_2)} \right) dy \quad (2.14)$$

Donc, la divergence de Kullback-Leibler s’annule lorsque les deux composantes de  $\mathbf{y}$  suivent la même loi :  $p_1(y_1) = p_2(y_2)$ .

La divergence de Kullback-Leibler permet de mesurer l’écart qui existe entre la densité conjointe et le produit des densités marginales. Cet écart est la mesure d’indépendance statistique. Plusieurs variables aléatoires  $y_i$  sont dites des composantes mutuellement indépendantes statistiquement si et seulement si :

$$p(\mathbf{y}) = p(y_1, y_2, \dots, y_q) = \prod_i p_i(y_i) \quad i = 1 \dots q \quad (2.15)$$

où  $p(\mathbf{y})$  est la distribution de  $\mathbf{y}$  et  $\prod_i p_i(y_i)$  est le produit de ses distributions marginales. Par conséquent, en remplaçant dans l’équation (2.14)  $p_1(y_1)$  par  $p(\mathbf{y})$  et  $p_2(y_2)$  par  $\prod_i p_i(y_i)$  et en minimisant la divergence Kullback-Leibler obtenue, on maximise l’indépendance des composantes  $y_i$ .

**Information mutuelle** L'information mutuelle peut être considérée comme la distance de Kullback-Leibler entre les densités conjointes et les densités marginales. Ainsi, l'information mutuelle de  $\mathbf{y}$  notée  $I(\mathbf{y})$ , peut être exprimée comme étant la divergence de Kullback-Leibler entre sa distribution  $p(\mathbf{y})$  et le produit de ses distributions marginales  $p(y_i)$  tel que :

$$I(\mathbf{y}) = D \left( p(\mathbf{y}) \middle| \prod_i p_i(y_i) \right) \quad i = 1 \dots q \quad (2.16)$$

En utilisant le concept de l'entropie différentielle [Cover et Thomas, 1991], on peut reformuler l'information mutuelle  $I(\mathbf{y})$  comme suit :

$$I(\mathbf{y}) = I(y_1, \dots, y_q) = \sum_i H(y_i) - H(\mathbf{y}) \quad (2.17)$$

en notant  $H(\mathbf{y})$  et  $H(y_i)$  les entropies jointes et marginales respectivement.

Les propriétés de l'information mutuelle suggèrent une estimation de la structure de séparation par minimisation de l'information mutuelle.

La minimisation de l'information mutuelle est un critère théorique suffisant, mais qui ne peut pas être appliqué en pratique (sous la forme de l'équation 2.17) en raison des problèmes dus à l'estimation. Différentes méthodes d'estimation qui conduisent à l'implémentation de différents critères d'indépendance ont été proposées pour résoudre ce problème.

L'approche algébrique classique en ACI proposée par P. Comon [Comon, 1994], passe par la néguentropie. La néguentropie est une mesure de l'entropie d'une variable aléatoire par rapport à l'entropie d'une variable de distribution gaussienne [Comon, 1994; Cardoso, 1998; Hyvärinen et Oja, 2000].

Par définition la néguentropie est la divergence de Kullback-Liebler entre une densité de probabilité  $p(\mathbf{y})$  et la densité de probabilité gaussienne  $g(\mathbf{y})$  de même moyenne et de même variance.

La néguentropie de  $\mathbf{y}$  notée  $J(\mathbf{y})$  est définie par,

$$J(\mathbf{y}) = H_g(\mathbf{y}) - H(\mathbf{y}) \quad (2.18)$$

où  $H_g(\mathbf{y})$  est l'entropie de la variable gaussienne (de même moyenne et de même variance).

En utilisant les définitions de l'information mutuelle et de la néguentropie,

$$I(\mathbf{y}) = J(\mathbf{y}) - \sum_i J(y_i) + \frac{1}{2} \log \frac{\prod_i v_{ii}}{\det \mathbf{V}} \quad (2.19)$$

où  $\mathbf{V}$  est la matrice de variance-covariance de  $\mathbf{y}$ , avec  $v_{ii}$  les éléments diagonaux. Étant donné que maximiser l'indépendance revient à minimiser l'information mutuelle, la maximisation de la somme des néguentropies marginales revient à minimiser l'information mutuelle après blanchiment des observations.

Cette méthode se rapproche aussi de celles utilisant la notion de kurtosis. On peut alors les caractériser par le fait qu'elles cherchent des sources les moins gaussiennes possibles.

Dans ces conditions, le problème de séparation consiste en la recherche d'une matrice de rotation  $\mathbf{J}$  telle que  $\sum_i H(y_i)$  soit minimale avec  $\mathbf{y}=\mathbf{Jz}$ .

Le développement est encore insuffisant, étant donné que la néguentropie est une mesure théorique. Comon [Comon, 1994] propose une méthode d'estimation de l'information mutuelle (et donc de la néguentropie) utilisant le développement d'Edgeworth des densités de probabilité, qui fait apparaître les cumulants d'ordre supérieur de la loi de probabilité, s'ils existent.

L'utilisation des moments (ou des cumulants) d'ordre deux n'est pas suffisante pour décider si des variables non gaussiennes sont indépendantes. Par contre, l'utilisation des cumulants (croisés) de tous ordres permet de montrer si des variables sont indépendantes ou non : si tous les cumulants croisés d'un ensemble de variables aléatoires de tous ordres sont nuls, alors les variables aléatoires sont indépendantes. Dans [Comon, 1994], Comon définit une fonction de contraste en utilisant les cumulants d'ordre quatre et montre que minimiser l'information mutuelle revient à maximiser la somme des carrés des cumulants d'ordre quatre ( $Cum_4$ )<sup>3</sup> des sources estimées :

$$I(\mathbf{y}) = \frac{1}{48} \sum_i (Cum_4)^2 \quad (2.20)$$

D'autres méthodes de séparation de sources proposées dans la littérature suivent dans leur principe la même démarche et sont fondamentalement équivalentes [Cardoso, 1999]. Les différences principales consistent dans la méthode choisie pour l'estimation de l'information mutuelle (ou de la néguentropie) [Hyvärinen, 1999; Bell et Sejnowski, 1995] ou alors dans la méthode de minimisation [Cichocki et Amari, 2002; Cardoso et Souloumiac,

---

3. Le cumulants d'ordre quatre ( $Cum_4$ ) de quatre variables aléatoires est défini par :  $Cum[a, b, c, d] = \mathbb{E}\{abcd\} - \mathbb{E}\{ab\}\mathbb{E}\{cd\} - \mathbb{E}\{ac\}\mathbb{E}\{bd\} - \mathbb{E}\{ad\}\mathbb{E}\{bc\}$ .

1993]. La liste d'algorithmes HOS présentée ci-dessous est extraite des toolbox Matlab ICALab [Cichocki *et al.*, 2009] et EEGLab [Delorme et Makeig, 2004], que nous avons utilisées pour la simulation.

- **FOBI** (*Fourth Order Blind Identification*) [Cardoso et CNRS, 1998] est basé sur les cumulants d'ordre quatre et permet de retrouver les composantes indépendantes sous réserve que celles-ci possèdent des kurtosis différents.
- **JADE** (*Joint Approximate Diagonalization of Eigen matrices*) [Cardoso et Souloumiac, 1993] présente une solution algébrique basé sur les cumulants d'ordre quatre et utilise l'algorithme de Jacobi [Cardoso et Souloumiac, 1996] dans le but de diagonaliser conjointement l'ensemble de matrices de cumulants.
- **RUNICA** [Makeig *et al.*, 1996] est l'implémentation de l'algorithme d'ACI Infomax [Bell et Sejnowski, 1995], basé sur la minimisation de l'information mutuelle,
- **FASTICA** (*Fixed-Point ICA*) [Hyvärinen et Oja, 1997; Hyvärinen, 1999] est un algorithme de point fixe pour ACI basé sur une estimation optimisée de la néguentropie.
- **UNICA** (*Unbiased quasi Newton algorithm for ICA*) [Cruces *et al.*, 2000] est un algorithme utilisé pour l'extraction d'un nombre donné de composantes indépendantes en présence du bruit gaussien dans le mélange. Cet algorithme exécute une itération quasi-newton [Cichocki et Amari, 2002] pour l'estimation du système de mélange.
- **SIMBEC** (*SIMultaneous Blind Extraction using Cumulants*) [Cruces *et al.*, 2001] est un algorithme qui exploite simultanément plusieurs fonctions de contraste pour la séparation de sources.
- **EFICA** (*Efficient Variant of FastICA*) [Koldovský *et al.*, 2006] est une version optimisée de l'algorithme FASTICA.
- **POWERICA** (*Power iteration for ICA*) [Ding, 2006] est un algorithme itératif d'ACI qui est basé sur une diagonalisation d'une matrice de covariance non linéaire, définie par les sorties d'ICA et la projection nonlinéaire des sorties d'ICA. La fonction d'activation qui caractérise la distribution de probabilité de sources est choisie comme opérateur de projection.
- **FAJD** (*Fast approximate joint diagonalization*) [Xi-Lin et Xian-Da, 2007] est un algorithme qui propose une approche rapide non orthogonale pour la diagonalisation jointe des matrices de quadri-covariance.



### 2.1.4.3 Séparation de sources par statistique d'ordre deux

Selon les hypothèses sur les différentes sources, l'utilisation de cumulants d'ordre supérieur n'est pas toujours nécessaire. Si les sources sont autocorrélées (ou non stationnaires), alors la statistique d'ordre deux fournit une solution qui s'avère satisfaisante y compris pour séparer des sources gaussiennes par exemple. L'hypothèse de départ sur les sources n'est donc plus leur indépendance statistique, mais une décorrélation plus "poussée" : pour pouvoir les séparer, les sources devront être soit décorrélées quel que soit leur décalage temporel, soit décorrélées quel que soit l'intervalle temporel même si elles sont non stationnaires.

**Diagonalisation simultanée.** Une des possibilités pour minimiser l'information mutuelle est de minimiser simultanément les cumulants croisés des sources estimées (algorithmes JADE, FAJD). Un exemple simple est la covariance : minimiser les différentes covariances implique une décorrélation des sources, donc la diagonalisation de la matrice de covariance. Cette décorrélation des sources estimées est une condition nécessaire de l'indépendance. En considérant en plus des matrices de cumulants croisés d'ordre supérieur, et en diagonalisant simultanément ces matrices, on obtient l'algorithme JADE.

La même méthode de diagonalisation simultanée peut s'appliquer en considérant non pas des matrices de cumulants d'ordre supérieur, mais des matrices de covariance décalées dans le temps ou estimées par fenêtre temporelle (on encore après d'autres manipulations sur les données, comme des filtres passe-bande, des transformations temps-fréquence ... [Congedo *et al.*, 2008]). Toutes ces matrices de covariance ont pour objectif, finalement, de coder l'information de dépendance (ou d'indépendance) des signaux, et elles seront estimées à partir des données mesurées.

La séparation de sources, sous certaines hypothèses de décorrélation, peut donc être obtenue par la diagonalisation simultanée de deux ou plusieurs matrices de covariance extraites des données. Si cette diagonalisation est réalisée après blanchiment, son objectif est de trouver la matrice orthogonale (de rotation)  $\mathbf{J}$  qui assure la séparation (éq. (2.12) et (2.13)). Autrement dit, ces méthodes cherchent une matrice unique, orthogonale, et qui diagonalise simultanément (même si c'est de manière approximative) un groupe de matrices de covariance.

L'application de la diagonalisation jointe sur des matrices de covariance décalées dans le temps (algorithmes SOBI / TDSEP) est détaillée dans les paragraphes suivants.

Comme vu précédemment la matrice de corrélation  $\mathbf{R}_x$  (pour un décalage  $\tau = 0$ ) est

blanchie en utilisant la matrice de blanchiment  $\mathbf{W}$ . Les signaux blanchis  $\mathbf{z}$  s'écrivent :

$$\mathbf{z} = \mathbf{W}\mathbf{x} = \Sigma_e^{-1/2}\mathbf{V}^T\mathbf{x}$$

et leur matrice de corrélation  $\mathbf{R}_z = \mathbf{I}$

Quel que soit le décalage  $\tau$ , on peut également définir une matrice de corrélation  $\mathbf{R}_{x(\tau)}$  :

$$\mathbf{R}_{x(\tau)} = \mathbb{E} \{ \mathbf{x}(k)\mathbf{x}(k + \tau)^T \} = \mathbf{A}\mathbb{E} \{ \mathbf{s}(k)\mathbf{s}(k + \tau)^T \} \mathbf{A}^T = \mathbf{A}\mathbf{R}_{s(\tau)}\mathbf{A}^T \quad (2.21)$$

et donc,

$$\mathbf{R}_{z(\tau)} = \mathbf{W}\mathbf{R}_{x(\tau)}\mathbf{W}^T = \Sigma_e^{-1/2}\mathbf{V}^T\mathbf{R}_{x(\tau)}\mathbf{V}\Sigma_e^{-1/2} \quad (2.22)$$

Une transformation unitaire peut être trouvée pour la diagonalisation de la matrice  $\mathbf{R}_{z(\tau)}$  pour un  $\tau$  donné. La décomposition de  $\mathbf{R}_{z(\tau)}$  en ses valeurs propres s'écrit :

$$\mathbf{R}_{z(\tau)} = \mathbf{J}\Sigma_2\mathbf{J}^T$$

où  $\Sigma_2$  est une matrice diagonale et  $\mathbf{J}$  une matrice orthogonale.

Donc en posant  $\mathbf{y}(k) = \mathbf{J}^T\mathbf{z}(k)$ , on satisfait :

$$\mathbf{R}_y = \mathbf{J}^T\mathbf{R}_z\mathbf{J} = \mathbf{I}$$

$$\mathbf{R}_{y(\tau)} = \mathbf{J}^T\mathbf{R}_{z(\tau)}\mathbf{J} = \Sigma_2$$

Ces deux matrices  $\mathbf{R}_z$  et  $\mathbf{R}_{z(\tau)}$  sont diagonalisées simultanément par la transformation linéaire

$$\mathbf{B} = \mathbf{J}^T\mathbf{W} = \mathbf{J}^T\Sigma_e^{-1/2}\mathbf{V}^T$$

qui satisfait l'équation (2.13).

Sur la figure 2.4, on montre la rotation des signaux blanchis c'est-à-dire les sources estimées  $\mathbf{y}$ . Ce développement est connu comme l'algorithme AMUSE (*Algorithm for Multiple Unknown Source Extraction based on EVD*) [Tong et al., 1991].

**Diagonalisation des matrices de covariance pour différents décalages.** En partant de l'hypothèse de sources stationnaires, autocorrélées et décorréélées quel que soit le décalage  $\tau$ , nous avons un ensemble de matrices de corrélation décalées  $\mathbf{R}_{x(\tau)}$  à diagonaliser, en utilisant la diagonalisation jointe approchée (la diagonalisation jointe exacte est généralement impossible) .




FIGURE 2.4. Exemple de signaux séparés à partir de statistique d'ordre deux

Soit  $\mathcal{R}_x = \{\mathbf{R}_{x(0)}, \mathbf{R}_{x(1)}, \dots, \mathbf{R}_{x(k)}\}$  l'ensemble de matrices de corrélation avec  $\mathbf{R}_{x(0)}$  est définie positive.

L'objectif est de déterminer la matrice de séparation  $\mathbf{B}$  de telle sorte que les matrices  $\mathbf{B}\mathbf{R}_{x(\tau)}\mathbf{B}^T$ ,  $\tau = 0, \dots, k$  soient les plus proches possibles de matrices diagonales.

La première étape est le blanchiment, celle-ci transformant  $\mathcal{R}_x$  en un nouvel ensemble,

$$\mathcal{R}_z = \{\mathbf{R}_{z(\tau)} = \mathbf{W}\mathbf{R}_{x(\tau)}\mathbf{W}^T\}, \quad \tau = 0, \dots, k \quad (2.23)$$

où  $\mathbf{R}_{z(0)} = \mathbf{I}$  (équation 2.11) et  $\mathbf{W}$  la matrice de blanchiment. Pour une matrice orthogonale  $\mathbf{J}$  quelconque,  $\mathbf{B} = \mathbf{J}^T\mathbf{W}$  réalise la diagonalisation exacte de  $\mathbf{R}_{x(0)}$ . On se ramène ainsi à la diagonalisation conjointe approchée de  $\mathcal{R}_z$ .

Soit  $O(\mathbf{M}) = \sum_{j \neq l} m^2(l, j)$  la somme des carrés des éléments hors diagonaux de  $\mathbf{M}$ . Le critère consiste à minimiser, par rapport à la matrice orthogonale  $\mathbf{J}$  la quantité,

$$C_\tau(\mathbf{J}, \mathbf{R}_{z(0)}) = \sum_{\tau=0}^k O(\mathbf{J}\mathbf{R}_{z(\tau)}\mathbf{J}^T) \quad (2.24)$$

La matrice  $\mathbf{J}$  est obtenue comme un produit de rotations successives de dimension 2 (voir l'algorithme détaillé dans [Cardoso et Souloumiac, 1996]).

Donc, l'estimation des sources est donnée par

$$\mathbf{y}(k) = \mathbf{J}^T \mathbf{z}$$

Cette méthode est connue sous l'acronyme SOBI (*Second Order Blind Identification*) [Belouchrani *et al.*, 1993; Belouchrani *et al.*, 1997].

**Diagonalisation des matrices de covariance sur fenêtres.** Sous l'hypothèse de sources stationnaires sur fenêtre et décorréelées, on partage les signaux  $\mathbf{x}(k)$  en  $k$  fenêtres (où les signaux sont considérés stationnaires).

Dans ce cas, au lieu de considérer plusieurs décalages, et donc plusieurs matrices de corrélation  $\mathbf{R}_{z(\tau)}$  pour différents décalages  $\tau$ , on peut aussi considérer plusieurs fenêtres et donc obtenir les  $\mathbf{R}_{z(k)}$  par fenêtre.

La diagonalisation jointe approchée (similaire au cas précédent) est appliquée sur les matrices  $\mathbf{R}_{z(k)}$ .

Cette méthode est connue sous l'acronyme SONS (*Second Order Nonstationary Source Separation*) [Choi et Cichocki, 2000] et s'applique surtout pour les signaux non stationnaires (mais supposés stationnaires par morceaux).

En dehors des algorithmes détaillés ci-dessus, nous présentons ici la liste des autres méthodes SOS que nous avons comparées en simulation :

- **WASOBI** (*Weights-Adjusted SOBI*) [Yeredor, 2000], qui est une extension de l'algorithme SOBI asymptotique et optimale pour sources auto-régressives (AR),
- **SOBI-BPF** (*Robust SOBI with bank of Band-Pass Filters*) [Cichocki et Belouchrani, 2001] qui utilise une diagonalisation jointe après l'application d'un banc de filtres passe-bande,
- **EVD2** (*SOS symmetric eigenvalue decomposition–EVD*) [Georgiev et Cichocki, 2001] qui fait une décomposition en valeurs-vecteurs propres (EVD) d'une matrice symétrique qui est une combinaison linéaire de plusieurs matrices de covariance décalées dans le temps,
- **EWASOBI** (*Efficient Weights-Adjusted SOBI*) [Tichavský *et al.*, 2006b] est une version optimisée de l'algorithme WASOBI,
- **QDIAG** (*Quadratic Optimization for Approximate Diagonalization*) [Vollgraf et Obermayer, 2006] est un algorithme pour la diagonalisation simultanée approchée de plusieurs matrices, qui relâche un certain nombre de contraintes (transformations orthogonales, matrices à diagonaliser symétriques, ...).

- **SAD** (*Sequential Approximate Diagonalization*) [Li et Zhang, 2007] est un algorithme efficace pour l'extraction séquentielle de sources en exploitant la SOS et en utilisant la diagonalisation jointe de matrices d'autocorrélation. Cet algorithme est capable d'extraire de sources spécifiques avec une connaissance *a priori*.

#### 2.1.4.4 Modifications (optimisations) des méthodes classiques

Afin d'optimiser les méthodes classiques de SAS et d'améliorer leurs applications, différentes modifications de ces méthodes ont été récemment proposées. Compte tenu de l'importance de ces modifications, nous présentons ici trois améliorations : le blanchiment robuste, les méthodes basées sur les transformées temps-fréquence et les méthodes combinées SOS et HOS.

**Blanchiment robuste.** Le blanchiment classique exploite la matrice de corrélation  $\mathbf{R}_x(0)$  au décalage  $\tau = 0$  donc, l'effet du bruit blanc ne peut pas être éliminé.

En supposant que le bruit est temporellement décorrélé, une manière de résoudre ce problème consiste à construire une matrice de blanchiment  $\bar{\mathbf{W}}$  non plus à partir de  $\mathbf{R}_x$ , mais plutôt à partir de  $k$  matrices de covariance  $\mathbf{R}_x(\tau)$  où  $\tau$  représente le décalage.

L'idée du blanchiment robuste est de considérer une combinaison linéaire de plusieurs matrices de corrélation décalées  $\mathbf{C}_x$  [Cichocki et Amari, 2002; Choi *et al.*, 2005],

$$\mathbf{C}_x = \frac{1}{2} \sum_{i=1}^k \{ \alpha_i \mathbf{R}_x(\tau)_i + \mathbf{R}_x^T(\tau)_i \} \quad (2.25)$$

où  $\alpha_i$  est un groupe de coefficients tel quel la matrice  $\mathbf{C}_x$  est définie positive.

On peut effectuer une décomposition EVD de la matrice  $\mathbf{C}_x$  [Cichocki et Amari, 2002],

$$\mathbf{C}_x = \mathbf{V} \Sigma_e \mathbf{V}^T$$

où  $\mathbf{V}$  est une matrice orthogonale et  $\Sigma_e$  la matrice diagonale de valeurs propres. La matrice de blanchiment obtenue est :

$$\bar{\mathbf{W}} = \Sigma_e^{-1/2} \mathbf{V}^T$$

avec les signaux blanchis  $\bar{\mathbf{z}} = \bar{\mathbf{W}}\mathbf{x}$ .

Le blanchiment robuste est utilisé dans les algorithmes SOBI-RO (*SOBI with Robust Orthogonalization*) [Belouchrani et Cichocki, 2000] et SEONS (*SEcond Order Nonstationary Source Separation*) [Choi *et al.*, 2002].

**Méthodes basées sur les représentations temps-fréquence.** Une catégorie d'approches développées plus récemment consiste à traiter le cas des sources non stationnaires en utilisant les propriétés temps-fréquence [Boashash *et al.*, 2003; Fadaili *et al.*, 2007; Févotte, 2003]. Elles sont fondées sur l'utilisation de représentations temps-fréquence spatiales (RTFS). L'idée d'utiliser des RTFS comme distribution conjointe des sources (à la place de matrices de covariances) a été introduite par [Belouchrani et Amin, 1998].

Ces techniques reposent toutes sur une étape préalable de sélection (automatique) de points temps-fréquence particuliers permettant la construction d'ensembles de matrices qui seront diagonalisées conjointement. Ces méthodes suivent généralement le même principe que les méthodes classiques (*i.e.* AMUSE, SOBI) à la différence du choix de l'opérateur linéaire appliqué aux observations. Elles diffèrent entre elles au niveau de la résolution des points temps-fréquence et des algorithmes de décompositions matricielles jointes utilisés. Ces méthodes nécessitent une étape préalable de blanchiment. La matrice de blanchiment est estimée de la même manière que les méthodes précédentes [Ghennioui, 2008].

Il faut mentionner également une autre classe de méthodes de représentation en temps-fréquence basée sur les ondelettes. La transformée en ondelettes est une représentation particulièrement parcimonieuse. L'utilisation des techniques de décomposition parcimonieuses des signaux pour la séparation de sources a été introduit par [Zibulevsky et Pearlmutter, 2001]. L'impact principal de ces méthodes est qu'elles fournissent un cadre relativement simple qui permet la séparation d'un nombre de sources plus grand que le nombre d'observations disponibles. L'idée de base est fondée sur une hypothèse essentiellement géométrique [Theis *et al.*, 2003].

**Méthodes combinées SOS et HOS.** De nouvelles méthodes utilisent à la fois la statistique d'ordre deux et la statistique d'ordre supérieur, ces combinaisons exploitant les avantages de deux techniques. Une liste des algorithmes comparés est présentée ci-dessous :

- **JADETD** (*Joint Approximate Diagonalization of Eigen matrices with Time Delays*) [Müller *et al.*, 1999] utilise une combinaison des algorithmes basés sur une structure temporelle d'ordre deux (l'algorithme TDSEP [Ziehe et Müller, 1998], similaire à SOBI) et de cumulants d'ordres supérieurs (l'algorithme JADE [Cardoso et Souloumiac, 1996]) : la diagonalisation jointe est appliquée simultanément sur des matrices de covariance décalées et des matrices de cumulants.
- **ThinICA** (*Thin algorithm for Independent Component Analysis*) [Cruces et Cichocki,

2003] est un algorithme capable d'extraire simultanément un nombre arbitraire de sources spécifié par l'utilisateur, basé également sur la maximisation de plusieurs cumulants et/ou matrices de covariances décalées à l'ordre deux.

- **COMBI**(*Combination of WASOBI and EFICA*) [Tichavský *et al.*, 2006a] est un algorithme capable d'estimer des sources non-gaussiennes et avec une structure temporelle au même temps en combinant l'algorithme d'ACI EFICA et l'algorithme de structure temporelle WASOBI.
- **MULTICOMBI** (*Multi-combination of WASOBI and EFICA*) [Tichavský *et al.*, 2008] est une amélioration de l'algorithme COMBI.

#### 2.1.4.5 Méthodes de séparation de sources et EEG

Comme nous venons de l'énoncer, de nombreux algorithmes et donc de méthodes ont été développés ces dernières années pour résoudre le problème de séparation de sources. Cependant, il n'existe pas de guide dans le choix de la méthode, ni en général pour les signaux EEG, ni en particulier pour l'identification des sources d'artéfacts. La seule possibilité, en dehors d'une comparaison en simulation, est de se baser sur des connaissances *a priori* sur les sources qui peuvent permettre de poser les hypothèses de travail. Comme nous l'avons vu précédemment, une partie importante de la communauté utilise les algorithmes HOS, spécialement Infomax et FastICA. Les résultats présentés par ces équipes confirment leur raisonnement : par exemple, les sources d'artéfacts oculaires ont une distribution non-gaussienne, typiquement avec un kurtosis élevé, donc les méthodes HOS devraient identifier ce type de source facilement. Cependant, selon nos analyses et suite aux discussions avec les neurologues, nous sommes enclins à suivre le raisonnement présenté par [Congedo *et al.*, 2008] et donc à appliquer plutôt des méthodes statistiques d'ordre 2. Selon l'auteur [Congedo *et al.*, 2008] deux aspects entrent en ligne de compte : statistiques et neurophysiologiques. En ce qui concerne le premier type, les considérations sont essentiellement dues à l'efficacité statistiques des SOS. En effet, elles peuvent être appliquées sur des intervalles plus courts ce qui représente un avantage compte tenu de l'hypothèse de modèles de mélanges linéaires instantanés. De plus, d'après [Belouchrani *et al.*, 1997] et [Joyce *et al.*, 2004] il semblerait que certaines méthodes SOS soient plus robustes vis-à-vis du bruit que les HOS car elles font référence à des moyennes d'ensembles <sup>4</sup>

---

4. Cette remarque n'est pas toujours recevable : par exemple, si le bruit est gaussien, il n'influence pas l'évaluation du kurtosis.

Le seconde considération est électroneurophysiologique. Le néocortex humain est un réseaux phénoménal d'interconnexions locales et globales. Les méthodes de séparation de sources de type HOS ou SOS peuvent être perçues comme des filtres spaciaux réduisant au minimum la dépendance des mélanges observés. Le fait de vouloir appliquer ces méthodes revient à dire en première hypothèse que les sources sont indépendantes. Cette hypothèse, vraisemblablement réaliste si les sources sont issues de processus indépendants (tels que les artéfacts), n'est pas nécessairement valide pour les sources de profondeur, qui peuvent se synchroniser en fonction de l'activité cérébrale.

Pour des données d'EEG de surface, c'est donc une méthode pour contrecarrer l'effet de la conduction de volume entre les générateurs d'artéfacts et les électrodes. Il est bien évident que le modèle de mélange linéaire instantané est un modèle dégradé qui ne prend pas en compte l'anisotropie des milieux, les formes, la structuration complexe du cortex. Toutefois, particulièrement en ce qui concerne les sources de contamination extra-cérébrale dont la nature, la localisation et la propagation sont très probablement mieux définies, ce modèle constitue un support acceptable.

En conséquence, nous avons choisi de comparer les différentes méthodes sur des signaux EEG simulés par des mélanges linéaires instantanés afin d'en déduire la méthode la plus adaptée pour l'élimination des artéfacts à travers des critères objectifs, puis d'appliquer cette méthode sur des signaux réels. Bien évidemment, cette approche reste critiquable dans le sens où les signaux simulés et le modèle de mélange ne représentent pas à eux seuls l'ensemble des scénarios possibles des situations réelles. Toutefois, il nous semble que cette étape permettra de faire une présélection des méthodes. L'application de méthodes de séparation de sources sur des EEG réels ne permettant pas de calculer des critères objectifs d'efficacité et de robustesse, nous exploiterons la validation médicale clinique comme critère.

## 2.2 Méthodologie de simulation

Comme précisé précédemment, il n'y a pas de consensus sur l'utilisation d'un algorithme de SAS pour l'identification des artéfacts EEG, et nous avons décidé de comparer les différentes méthodes sur des EEG simulés. Nous avons conscience de la difficulté de simuler des signaux et un mélange au plus près des processus réels. Toutefois quelles que soient les erreurs que nous pourrions commettre sur les modèles de sources, notre objectif est d'évaluer les performances et la robustesse des différents algorithmes de séparation SOS ou HOS en fonction de la structuration de la matrice de mélange et du



bruit<sup>5</sup>.

Afin d'obtenir des résultats fiables, il est nécessaire dans un premier temps de définir un critère d'évaluation des performances.

### 2.2.1 Critère d'évaluation pour la SAS

Un des critères les plus utilisés pour cette évaluation est l'indice de séparabilité  $IS$  [Cichocki et Amari, 2002]. Cet indice est calculé à partir de la matrice de transfert  $\mathbf{G}$  ( $P \times P$ ), entre les sources d'origine et les sources estimées données par :

$$\mathbf{G} = \mathbf{B}\mathbf{A}$$

Pour obtenir l' $IS$  il est nécessaire de prendre la valeur absolue des éléments de  $\mathbf{G}$  et de normaliser les lignes  $\mathbf{g}_i$  en divisant chaque élément par la valeur absolue maximum de la ligne. Les lignes de la matrice résultante  $\mathbf{G}'$  seront :

$$\mathbf{g}_i' = \frac{|\mathbf{g}_i|}{\max |\mathbf{g}_i|} \quad (2.26)$$

L'indice de séparabilité est obtenu à partir de la nouvelle matrice  $\mathbf{G}'$  en calculant :

$$IS = \frac{\sum_{i=1}^P \left( \sum_{j=1}^P (\mathbf{G}'(i, j)) - 1 \right)}{P(P-1)} \quad (2.27)$$

Pour une séparation idéale l' $IS$  doit être égal à 0.

Évidemment, les performances d'un algorithme dépendent des signaux de test. Il est donc nécessaire de simuler différentes situations, tout en restant proche des conditions réelles. La démarche de comparaison que nous proposons est la suivante :

1. Choix des meilleurs algorithmes de séparation pour l'application EEG dans des conditions de mesure idéales (sans bruit). Comme la matrice de mélange est inconnue, plusieurs simulations seront réalisées en considérant des matrices aléatoires et les algorithmes seront choisis en fonction de la valeur moyenne du critère d'évaluation ( $IS$ ). L'écart type sera également évalué, ce qui nous permettra de vérifier la sensibilité des algorithmes par rapport aux variations de la matrice de mélange.
2. Analyse des performances et de la robustesse des algorithmes choisis par rapport au bruit (changements de la distribution et de la puissance dans une plage évaluée en fonction des EEG réels).

---

5. Les artéfacts sont considérés comme des sources

## 2.2.2 Signaux de test

Les enregistrements d'EEG sont issus de mélanges de différentes sources neuronales indépendantes, des artéfacts et de bruits. Ces différentes sources, ainsi que le système de mélange, sont inconnus. Afin de déterminer les algorithmes de SAS les plus appropriés pour le pré-traitement des signaux d'EEG, nous avons travaillé sur des signaux d'EEG simulés, créés à partir de sources, de matrices de mélange et de bruits connus.

Nous avons créé différents modèles d'EEG simulés en mélangeant des sources simulées indépendantes, dont les caractéristiques sont proches de l'activité normale ou pathologique (activité épileptique) du cerveau et des artéfacts extra-cérébraux, et en ajoutant au mélange un bruit additif.

Comme discuté précédemment, un nombre minimal d'échantillons (longueur minimale de la fenêtre) est nécessaire pour faire une séparation de sources statistiquement fiable. Il faut noter que, pour les signaux réels, le nombre maximal de points (taille maximale de la fenêtre) est limité par des contraintes de stationnarité, nécessaires pour une estimation correcte des paramètres statistiques intervenant dans la SAS. Cette problématique sera abordée ultérieurement (cf. section 3.2.1.2).

### 2.2.2.1 Simulation de sources d'activité normale

Le groupe de sources simulées d'activité normale contient six sources (figure 2.5). Les sources S1, S3, S4 et S5 sont composées par des successions de sinusoides de fréquences comprises entre 0.5 et 30 Hz (bandes électrophysiologiques d'EEG). La source S2 est proche d'ondes générées par les clignements oculaires (artéfact oculaire – fréquences dans la bande électrophysiologique delta) et la source S6 est une source simulée d'EEG d'un nouveau né développée par [Rankine *et al.*, 2007]. Ce dernier signal est modélisé à partir des caractéristiques non stationnaires des signaux de EEG réels (spectre de puissance à court terme avec la loi de puissance variable dans le temps selon une loi empirique déduite des mesures réelles).

La fréquence d'échantillonnage considérée est celle de l'application clinique courante, c'est-à-dire 256 Hz. Pour vérifier et assurer la fiabilité des résultats de séparation, nous avons considéré différentes longueurs des sources, de 1024 points (4 secondes, environ 30 fois le nombre de sources  $P$  au carré) à 4096 échantillons (16 secondes, plus de 100 fois  $P^2$ ). Les résultats ne sont pas significativement différents, ce qui est attendu pour des sources simulées et des mélanges constants.




FIGURE 2.5. Sources simulées d'activité normale

### 2.2.2.2 Simulation de l'EEG normal

Deux modèles d'EEG d'activité normale ont été simulés : un premier modèle en conditions idéales (sans bruit) et le deuxième en ajoutant un bruit additif.

Les six sources simulées d'activité normale ont été mélangées en utilisant une matrice de mélange aléatoire carrée (distribution uniforme entre -1 et 1), afin d'obtenir six voies d'EEG simulé. Un exemple de signaux EEG simulés sans bruit (équation 2.1) est présenté dans la figure 2.6.




FIGURE 2.6. EEG d'activité normale simulé non bruité

**Simulation du bruit.** Afin d’obtenir des simulations plus réalistes, chaque voie d’EEG simulé a été bruitée indépendamment. Bien évidemment, se pose alors la question de l’ordre de grandeur du bruit à simuler pour se rapprocher des signaux réels : quel rapport signal/bruit (SNR) doit-on simuler ?

Pour répondre à cette question nous avons estimé le SNR sur des EEG réels à partir de l’estimation de l’écart-type du bruit  $\sigma_n$ . Cette estimation est faite à l’aide des techniques utilisées dans le débruitage par ondelettes, décrites dans le chapitre 4. Si, dans un premier temps, le bruit est considéré blanc, son énergie est équi-répartie sur toutes les bandes de fréquence (les échelles) de la décomposition. En conséquence, on peut estimer l’écart-type du bruit dans une bande où le signal informatif est considéré inexistant ou quasi-inexistant, notamment dans les plus hautes fréquences, c’est-à-dire à partir des coefficients d’ondelette de la première échelle [64–128Hz] de la décomposition (dans notre application, cette échelle est effectivement considérée non informative car les fréquences qu’elle contient sont supérieures aux fréquences des bandes électrophysiologiques). Comme pour le débruitage, nous avons utilisé l’estimateur robuste de  $\sigma_n$  (4.8).

Le SNR a été calculé sur 10 enregistrements d’EEG, chacun avec 24 signaux mesurés  $x$ , selon :

$$SNR = 20 \log_{10} \frac{\sigma_x - \widehat{\sigma}_n}{\widehat{\sigma}_n} \quad (2.28)$$

La valeur moyenne des 24 signaux a été obtenue pour chaque EEG. Ces valeurs moyennes se trouvent entre 4.5dB et 18.6dB. A partir de cette estimation, nous avons décidé d’utiliser 4 valeurs de SNR pour les simulations : 5dB, 10dB, 15dB et 20dB.

Différentes distributions de bruit ont été également testées pour les 4 écart-types (SNR) considérés : distributions uniforme, gaussienne et laplacienne, toutes de moyenne nulle.

La deuxième question relative à la simulation du bruit porte sur le contenu fréquentiel du bruit présent dans les signaux d’EEG : ce bruit doit-il être blanc ou coloré ?

La réponse est difficile, car nous n’avons pas à disposition des portions du signal contenant uniquement du bruit, qui pourraient servir à une analyse plus exacte. Une approximation du contenu fréquentiel du bruit, à utiliser avec précaution comme nous allons l’expliquer ci-dessous, peut être obtenue à partir de l’estimation de la variance du bruit par échelle de la décomposition en ondelettes (même estimateur robuste (4.8), mais appliqué échelle par échelle). Si, pour un signal EEG, on a des valeurs similaires pour chaque échelle de la décomposition (pour chaque  $j$ ) c’est-à-dire si le bruit est équi-réparti

sur toutes les échelles, on peut considérer que le bruit est blanc, dans le cas contraire (différentes valeurs pour chaque échelle) on a un bruit coloré. Nous avons utilisé 10 enregistrements d'EEG réel avec 24 voies chacun en nous avons estimé le bruit sur chacune des 6 échelles ( $j = 1 \dots 6$  échelles de décomposition) de chaque signal.

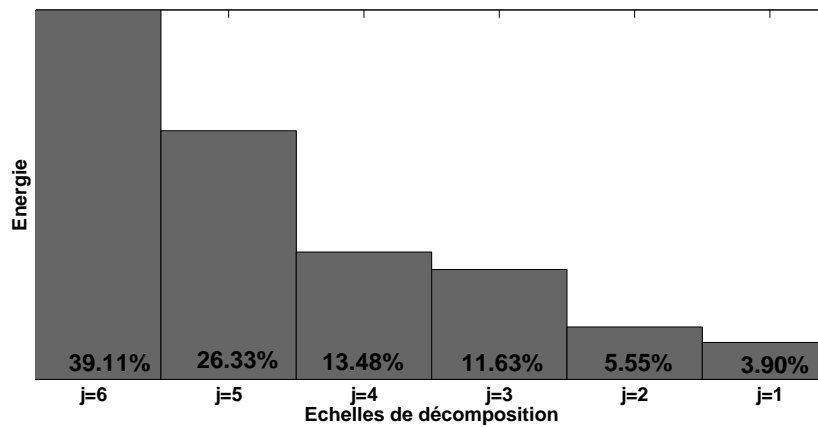
Les résultats obtenus sur les 10 enregistrements montrent que la plupart des signaux ont des valeurs très différentes pour chaque échelle. Ces valeurs sont plus élevées sur les 3 dernières échelles (2–16 Hz), donc dans les basses fréquences, ce qui semble indiquer que le bruit est plus présent dans les basses fréquences où le signal informatif d'EEG est également présent. Ce constat incite à la prudence : en effet, l'estimateur à base d'ondelettes, bien qu'en principe robuste aux valeurs aberrantes des coefficients d'ondelette (outliers), peut être influencé si ces valeurs sont nombreuses. En principe, par la nature de la décomposition en ondelettes (voir discussion dans le chapitre 4), les grandes valeurs correspondent au signal, et donc une présence importante du signal informatif sur une échelle peut conduire à une mauvaise estimation du bruit. Cependant, pour cette simulation, nous avons considéré l'estimateur fiable, même si ceci sera mis en cause au moment de l'introduction du débruitage, chapitre 4.

Dans un premier temps le bruit a été considéré blanc. Dans un deuxième temps, il a été remplacé par un bruit coloré obtenu par filtrage du bruit blanc de distribution gaussienne par un banc de filtres FIR passe-bande, synthétisés pour générer un bruit dont le contenu fréquentiel soit similaire à l'estimé. Les valeurs des écarts-types obtenues pour chaque échelle de décomposition (valeurs moyennes pour les 10 enregistrements analysés) ont été utilisées pour calculer les gains des réponses fréquentielle des filtres (voir figures 2.7(a) et 2.7(b) pour les valeurs relatives de la puissance du bruit par échelle).


Un exemple d'EEG simulé d'activité normale bruitée est présenté à la figure 2.8.

## 2.3 Résultats

La présentation des résultats suit la démarche introduite au début de la section 2.2 : application de méthodes SAS dans des conditions idéales de simulation, suivie de l'évaluation de la robustesse des algorithmes par rapport aux variations de la matrice de mélange et dans des conditions de mesure bruitées. Une partie de ces travaux a fait l'objet de plusieurs publications [Romo-Vázquez *et al.*, 2007a; Romo-Vázquez *et al.*, 2007b; Salido-Ruiz *et al.*, 2008].



(a) Réponse fréquentielle du filtre




(b) Périodogramme du bruit coloré génère

**FIGURE 2.7.** Génération du bruit coloré

### 2.3.1 Signaux sans bruit, matrice de mélange inconnue

L'objectif de cette première série de comparaisons est de choisir un ensemble d'algorithmes de séparation de sources, les plus appropriés pour notre application, sur des EEG simulés en conditions idéales (sans bruit). Vingt-trois algorithmes de SAS (voir la liste dans la section précédente) ont été appliqués pour estimer la matrice de séparation et par conséquent les sources. Le critère d'évaluation de performance employé est l'indice de séparabilité  $IS$  (2.27).

Pour chaque algorithme, nous avons simulé 1000 EEG à partir des mêmes sources décrites précédemment, en utilisant des matrices de mélange aléatoires de distribution



**FIGURE 2.8.** EEG d'activité normale simulé bruité

uniforme dans l'intervalle  $[-1 \ 1]$ . Les  $IS$  obtenus ont été moyennés et les 10 meilleures performances sont présentées dans le tableau 2.1.


**TABLE 2.1.** Moyenne et écart-type de l' $IS$  en conditions idéales (sans bruit). L'EEG a été simulé avec 1000 réalisations de la matrice de mélange

	Algorithme SAS	$\mu_{IS}$	$\sigma_{IS}$
1	MULTICOMBI	0.0232	0.0192
2	COMBI	0.0288	0.0022
3	EFICA	0.0288	0.0022
4	SOBI	0.0292	$< 10^{-4}$
5	SEONS	0.0293	0.0045
6	SOBI-RO	0.0309	0.0005
7	WASOBI	0.0346	$< 10^{-4}$
8	FASTICA	0.0363	0.0014
9	AMUSE	0.0467	$< 10^{-4}$
10	THINICA	0.0544	0.0015

Comme on peut le voir, tous les algorithmes présentés ici ont un  $IS$  inférieur à 0.1, ce qui est vrai d'ailleurs pour la plupart des 23 algorithmes testés (un bémol pour un des algorithmes les plus utilisés dans le domaine de l'EEG, RUNICA/ Infomax, qui se classe le 21<sup>me</sup>, avec un  $IS$  moyen de 0.1712).

En analysant le tableau 2.1 on voit que la meilleure performance est obtenue par l'algorithme combiné MULTICOMBI qui se distingue des autres algorithmes. On peut également remarquer un groupe de 5 algorithmes avec de très bonnes performances (COMBI, EFICA, SEONS, SOBI et SOBI-RO). Ces 6 algorithmes sont les plus performants et sont basés sur la SOS (uniquement ou en combinaison avec la HOS) hormis l'algorithme EFICA basé sur HOS uniquement. Étant donné que les algorithmes sont classés par ordre de performance, les quatre derniers sont WASOBI, FASTICA, AMUSE, THINICA. Par ailleurs, notons que les algorithmes combinés (COMBI et MULTICOMBI) améliorent les résultats obtenus séparément par les algorithmes qui les constituent (EFICA et WASOBI).

Dans la figure 2.9 sont montrés synthétiquement les  $IS$  moyens et les écarts-types (en pointillés) pour les 1000 simulations. En analysant cette figure (ainsi que le tableau 2.1) on voit que les 4 algorithmes présentant les meilleurs résultats pour l' $IS$  sont les plus instables (écart-type élevé) vis-à-vis des variations de la matrice mélange, particulièrement l'algorithme MULTICOMBI. Les algorithmes les plus stables sont SOBI, SOBI-RO, WASOBI, et AMUSE (tous d'eux basés sur la SOS).



**FIGURE 2.9.**  $IS$  moyen et écart type pour les 10 meilleurs algorithmes : 1. MULTICOMBI, 2. COMBI, 3. EFICA, 4. SEONS, 5. SOBI, 6. SOBI-RO, 7. WASOBI, 8. FASTICA, 9. AMUSE, 10. THINICA.

De manière générale, on peut conclure que pour cette application et en conditions idéales, les algorithmes qui impliquent la statistique d'ordre deux, seule ou en combinaison avec la HOS présentent les meilleures performances. Cependant, il est clair que les résultats présentés dépendent des sources employées et donc du réalisme de la simula-



tion. Plusieurs tests ont été réalisés, sous contrôle médical, sur des EEG réels, et quelques exemples seront présentés à la fin de ce chapitre.

### 2.3.2 Signaux bruités, matrice de mélange commune

La sous-section précédente présente une évaluation de la robustesse des algorithmes face aux variations de la matrice mélange. Cependant, ces évaluations sont faites sur des signaux non bruités. Nous présentons ici une analyse des performances et de la robustesse des algorithmes de séparation sélectionnés, dans des conditions plus réalistes, c'est-à-dire en y ajoutant du bruit.

Dans la section précédente (section 2.2, sous-section 2.2.2.2), nous avons présenté une évaluation du bruit qui perturbe les EEG réels, en constatant que les rapports signal/bruit peuvent varier approximativement entre 20 et 5dB. Autrement dit, dans le cas des signaux réels, le mélange n'est pas idéal et donc il est nécessaire soit :

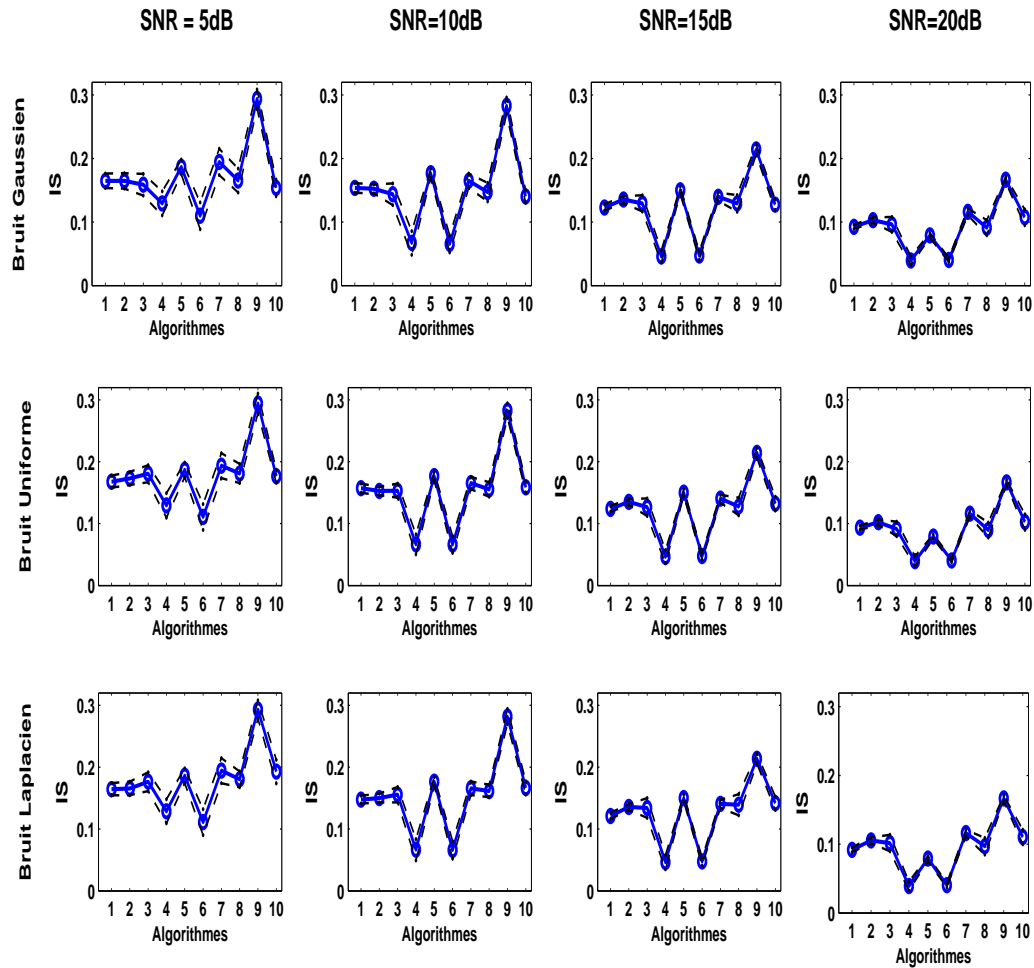
1. de tester la robustesse des algorithmes face au bruit et de choisir en fonction des performances dans une situation plus réaliste,
2. d'éliminer le bruit avant la séparation, et donc d'introduire une étape de débruitage.

Ce dernier point sera abordé dans le chapitre 4, qui propose l'introduction d'un algorithme de débruitage par ondelettes dans la chaîne de traitement.

Nous avons donc mesuré l'influence du bruit dans l'estimation de la matrice de séparation et donc les performances des algorithmes en fonction du bruit. Dans un premier temps, la matrice de mélange a été fixée et elle a été choisie "représentative" des performances moyennes pour chacun des 10 algorithmes : pour la matrice choisie, leurs performances dans de conditions idéales, sont proches des valeurs moyennes obtenues au paragraphe précédent (tableau 2.1).

Nous avons évalué le comportement et la robustesse des algorithmes de SAS pour plusieurs combinaisons distribution du bruit – SNR. Plus précisément, nous avons considéré 3 distributions du bruit : gaussienne, uniforme et laplacienne et 4 valeurs de SNR : 5dB, 10dB, 15dB et 20dB.


Selon les résultats des simulations, ces facteurs n'ont pas la même influence sur les indices de séparabilité obtenus. La figure 2.10 présente une image synthétique des variations de l'*IS* en fonction de ces 2 facteurs. Les valeurs présentées sont des *IS* moyens pour 1000 simulations, les écarts-types figurent en pointillés.



**FIGURE 2.10.** Robustesse des algorithmes de séparation (type du bruit et SNR) pour les 10 algorithmes de SAS (algorithmes : 1. MULTICOMBI, 2. COMBI, 3. EFICA, 4. SEONS, 5. SOBI, 6. SOBI-RO, 7. WASOBI, 8. FASTICA, 9. AMUSE, 10. THINICA. )

En analysant la figure 2.11, on peut conclure rapidement que, dans des conditions bruitées, le classement des algorithmes n'est plus le même qu'en conditions dites idéales<sup>6</sup>. En effet, quelles que soient la distribution et la puissance du bruit, les résultats mettent en évidence que les deux algorithmes les plus performants sont SEONS et SOBI-RO : tous les deux sont basés sur la statistique d'ordre deux et incluent une étape de blanchiment robuste, alors que le moins performant est AMUSE (statistique d'ordre deux aussi, mais

6. Pour faciliter la lecture et les comparaisons, nous gardons néanmoins le même ordre des algorithmes dans les tableaux et les graphiques suivants.



**FIGURE 2.11.** Performances des algorithmes de séparation en fonction de la distribution du bruit

sans blanchiment robuste et en considérant seulement deux matrices de covariance à diagonaliser).

Une autre observation immédiate est la faible influence de la distribution du bruit : en effet, il semblerait que, quelle que soit la distribution (uniforme, gaussienne ou laplacienne), les valeurs des indices de séparabilité sont sensiblement les mêmes.

Enfin, la puissance du bruit joue un rôle plus important et le niveau général des  $IS$  diminue avec l'augmentation du rapport signal sur bruit : ce résultat était assez attendu.

Par la suite, nous nous intéressons plus en détail à l'influence de ces deux paramètres qui sont la distribution du bruit et les SNR sur l'indice de séparabilité  $IS$ . Nous allons évaluer à la fois leur influence sur les performances moyennes et sur la stabilité des algorithmes : les  $IS$  obtenus après l'application des différents algorithmes varient-ils beaucoup ou peu autour de leur valeurs moyennes ? Cette variation dépend-elle de la distribution ?

Concernant le type de bruit (distribution gaussienne, uniforme ou laplacienne), on

voit à la figure 2.10 que l'*IS* varie très peu en fonction du type du bruit. Une présentation alternative, plus détaillée, est fournie par la figure 2.11. Ces performances montrent que les 5 algorithmes basés uniquement sur la statistique d'ordre deux sont quasi-insensibles aux variations de la distribution du bruit, alors que les algorithmes basés sur la statistique d'ordre supérieur et les algorithmes combinés sont plus sensibles à ces variations, même si cette sensibilité reste faible. Il est intéressant de remarquer que les performances de ces algorithmes diminuent pour les bruits à kurtosis grand (distribution à queues lourdes, comme le bruit laplacien), ce qui était finalement assez attendu également, étant donné qu'ils sont basés sur l'estimation de cumulants d'ordre supérieur et que cette estimation est plus affectée par un bruit laplacien que par un bruit uniforme ou gaussien.

Pour avoir une image quantitative de ces résultats, les valeurs moyennes de l'*IS* et les écarts-types sont présentés dans le tableau 2.2. Ce tableau confirme d'abord les meilleures performances moyennes de SOBI-RO et SEONS, qui dépassent largement les autres. Quant à la stabilité des algorithmes, il semble que MULTICOMBI, COMBI et SOBI sont les plus stables, suivis par un groupe constitué de la majorité des autres algorithmes, hormis FASTICA et sa version EFICA, qui semblent plus sensibles au bruit, et de SEONS. Il est utile de remarquer ici que les performances d'une partie des algorithmes dépendent de leur initialisation (matrice de mélange/séparation estimée à l'itération 0), qui est souvent aléatoire.

Une première conclusion est donc que la distribution du bruit a relativement peu d'influence sur les performances des algorithmes de séparation, même si cette influence est légèrement plus importante pour les algorithmes HOS. Ce constat est valable à la fois en ce qui concerne la performance moyenne et la stabilité des méthodes comparées.

Cette conclusion nous amène à analyser les algorithmes de SAS par rapport à leur sensibilité à la puissance du bruit, qui est évidemment plus importante. Les résultats présentés par la suite concernent principalement le bruit gaussien, mais ils sont similaires à ceux obtenus pour les autres distributions.

La figure 2.12 montre l'*IS* moyen pour les 10 algorithmes afin d'évaluer leur comportement pour les 4 valeurs de SNR. En analysant cette figure, on peut classer les algorithmes en 3 groupes, selon les valeurs moyennes de l'*IS* :

- Le premier groupe contient les 2 meilleures performances : SEONS et SOBI-RO, avec de très bons résultats pour l'*IS*. Ces deux algorithmes sont basés sur la SOS et intègrent un blanchiment robuste. Les valeurs de l'écart-type montrent aussi que l'algorithme SOBI-RO est moins sensible que l'algorithme SEONS ;
- Le deuxième groupe contient 7 algorithmes : 3 algorithmes combinés (MULTI-

**TABLE 2.2.** Moyenne et écart-type de l' $IS$  par type de bruit. L'EEG a été simulé avec une matrice de mélange fixée et 1000 réalisations du bruit aléatoire par SNR (4 niveaux) et par distribution (3 types)

	Algorithme SAS	Bruit		Gaussien		Uniforme		Laplacien	
		$\mu_{IS}$	$\sigma_{IS}$	$\mu_{IS}$	$\sigma_{IS}$	$\mu_{IS}$	$\sigma_{IS}$	$\mu_{IS}$	$\sigma_{IS}$
1	MULTICOMBI	0.1334	0.0069	0.1356	0.0063	0.1313	0.0062		
2	COMBI	0.1388	0.0072	0.1408	0.0065	0.1392	0.0067		
3	EFICA	0.1319	0.0147	0.1379	0.0128	0.1419	0.0139		
4	SEONS	0.0703	0.0135	0.0704	0.0135	0.0702	0.0136		
5	SOBI	0.1481	0.0071	0.1482	0.0069	0.1480	0.0071		
6	SOBI-RO	0.0657	0.0111	0.0663	0.0109	0.0664	0.0112		
7	WASOBI	0.1539	0.0110	0.1539	0.0104	0.1543	0.0106		
8	FASTICA	0.1331	0.0146	0.1384	0.0134	0.1445	0.0131		
9	AMUSE	0.2394	0.0100	0.2395	0.0100	0.2388	0.0098		
10	THINICA	0.1322	0.0110	0.1424	0.0108	0.1528	0.0128		

COMBI, COMBI et THINICA), 2 algorithmes basés sur l'HOS uniquement (EFICA et FASTICA) et 2 basés sur SOS uniquement (WASOBI et SOBI). Ces 7 algorithmes présentent des valeurs moyennes d' $IS$  intermédiaires et relativement stables par rapport aux variations de SNR, sauf pour SOBI, qui s'améliore nettement pour un bruit faible ;

- Le dernier groupe est constitué d'un seul algorithme, AMUSE, qui présente les valeurs moyennes d' $IS$  les plus élevées quel que soit le SNR, même s'il s'améliore beaucoup en présence de bruit relatif faible.

Évidemment, les performances des 10 algorithmes tendent à se rapprocher pour les puissances de bruits importantes (tous séparent difficilement les sources) ou pour les bruits faibles (tous séparent assez bien, voir le tableau 2.1 pour un classement plus précis).

Comme pour la distribution du bruit, nous présentons les résultats numériques (moyenne et écart-type) de l' $IS$  par puissance de bruit dans le tableau 2.3.

En général, on peut conclure que les algorithmes qui utilisent la SOS en combinaison avec un blanchiment robuste sont les plus performants, avec SOBI-RO légèrement moins sensible au bruit que SEONS (meilleures performances moyennes, sauf pour un bruit très faible, ainsi qu'une meilleure stabilité – écart-type de l' $IS$  plus faible). Les autres al-




FIGURE 2.12. Performances des algorithmes de séparation en fonction de SNR

algorithmes, à l'exception de AMUSE, ont des performances assez similaires, légèrement inférieures pour les méthodes purement SOS comme WASOBI et SOBI (mais ce dernier s'améliore rapidement pour un SNR plus grand). Il est intéressant de remarquer que, selon nos comparaisons, l'introduction du blanchiment robuste dans les algorithmes HOS de type FASTICA/EFICA n'améliore pas leur performances moyennes.

En ce qui concerne la robustesse de ces résultats, les simulations nous permettent de conclure que les deux meilleurs algorithmes (SOBI-RO et SEONS) ne sont pas parmi les plus robustes face aux variations aléatoires dues au bruit (écarts-types relativement grands, surtout par rapport à MULTICOMBI, COMBI et SOBI), mais ceci ne remet pas vraiment en cause le classement : il y a peu de chance que, pour une matrice de mélange "moyenne", l'ordre des algorithmes change pour une réalisation particulière du bruit.

Ces résultats confirment les résultats présentés dans [Choi *et al.*, 2002; Cichocki et Amari, 2002] où il est indiqué que les algorithmes SOS avec blanchiment robuste sont les plus performants pour la séparation de mélanges bruités.

**TABLE 2.3.** Moyenne et écart-type de l'IS par puissance de bruit (SNR). L'EEG a été simulé avec une matrice de mélange fixée au préalable et 1000 réalisations de bruit aléatoire gaussien par SNR (4 niveaux)

SNR Algorithme		5 dB		10dB		15dB		20dB	
		$\mu_{IS}$	$\sigma_{IS}$	$\mu_{IS}$	$\sigma_{IS}$	$\mu_{IS}$	$\sigma_{IS}$	$\mu_{IS}$	$\sigma_{IS}$
1	MULTICOMBI	0.1648	0.0115	0.1536	0.0078	0.1229	0.0050	0.0923	0.0032
2	COMBI	0.1647	0.0122	0.1522	0.0071	0.1354	0.0051	0.1030	0.0042
3	EFICA	0.1587	0.0172	0.1437	0.0171	0.1292	0.0129	0.0961	0.0118
4	SEONS	0.1293	0.0190	0.0670	0.0188	0.0458	0.0097	<b>0.0393</b>	0.0066
5	SOBI	0.1868	0.0116	0.1767	0.0074	0.1498	0.0057	0.0790	0.0037
6	SOBI-RO	<b>0.1097</b>	0.0211	<b>0.0655</b>	0.0135	<b>0.0472</b>	0.0064	0.0403	0.0033
7	WASOBI	0.1946	0.0207	0.1650	0.0113	0.1398	0.0064	0.1161	0.0054
8	FASTICA	0.1652	0.0189	0.1470	0.0145	0.1292	0.0132	0.0910	0.0118
9	AMUSE	0.2938	0.0148	0.2830	0.0129	0.2142	0.0080	0.1666	0.0042
10	THINICA	0.1537	0.0131	0.1404	0.0100	0.1273	0.0084	0.1073	0.0125

### 2.3.3 Signaux bruités, matrice de mélange inconnue

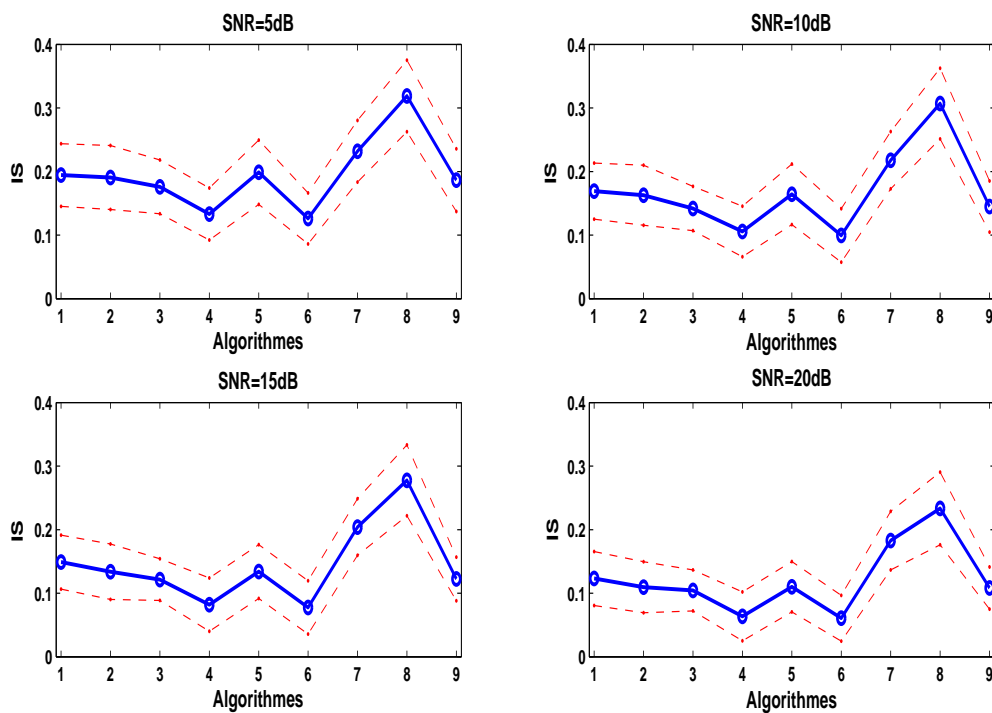
En ce qui concerne la sensibilité des algorithmes par rapport aux variations aléatoires du bruit ou de la matrice de mélange, les deux facteurs semblent avoir une influence du même ordre de grandeur, bien que, pour un bruit de faible puissance, les écarts-types  $\sigma_{IS}$  sont plus faibles, comme les moyennes  $\mu_{IS}$  (voir tableaux 2.1 et 2.3). Il est donc probable que, en faisant varier à la fois le mélange et le bruit additif, les performances des algorithmes varient plus autour de leur valeurs moyennes, mais il est peu probable que leur classement change.

Une dernière comparaison a été faite pour valider ce raisonnement. Nous avons procédé à un dernier type de simulations, en faisant varier la matrice de mélange d'une manière aléatoire (comme pour les premières comparaisons en conditions idéales), mais en rajoutant aux signaux mélangés un bruit aléatoire (gaussien), avec différents SNR (1000 matrices par SNR).

Les 10 algorithmes précédemment choisis ont été inclus dans cette simulation. Cependant, selon nos simulations, l'algorithme FASTICA est très sensible aux valeurs des coefficients de la matrice de mélange en conditions bruitées et il ne converge pas tou-

jours ; il a donc été retiré du protocole de test. La figure 2.13 présente les résultats pour les 9 algorithmes restants : MULTICOMBI, COMBI, EFICA, SEONS, SOBI, SOBI-RO, WASOBI, AMUSE et THINICA. Les résultats moyens de l'IS et les écarts-types pour les 1000 simulations sont représentés. Les résultats numériques sont présentés dans le tableau 2.4. Ils permettent de mettre en évidence plusieurs constats :

- L'ordre des algorithmes est globalement inchangé : dans des conditions bruitées, les variations aléatoires de la matrice de mélange ne changent pas le classement obtenu avec une matrice de mélange fixe.
- En revanche, les écarts-types sont sensiblement plus grands, et ce classement, correct en moyenne, peut changer sur des exemples particuliers.
- Les écarts-types sont relativement constantes quel que soient les algorithmes mis en œuvre, et ils varient très peu avec la puissance du bruit (tableau 2.4).



**FIGURE 2.13.** Robustesse des 10 algorithmes de séparation (algorithmes : 1 MULTICOMBI, 2 COMBI, 3 EFICA, 4 SEONS, 5 SOBI, 6 SOBI-RO, 7 WASOBI, 8 AMUSE, 9 THINICA.)

En conclusion, il semblerait que, dans des conditions réalistes (matrice de mélange inconnue, bruit additif inconnu), les performances des algorithmes soient assez variables, et qu'il n'est pas possible de choisir une méthode dont les performances soient particu-



**TABLE 2.4.** Moyenne et écart-type de l'IS par puissance de bruit (SNR). L'EEG a été simulé avec 1000 réalisations de la matrice de mélange et une réalisation du bruit gaussien par SNR (4 niveaux)

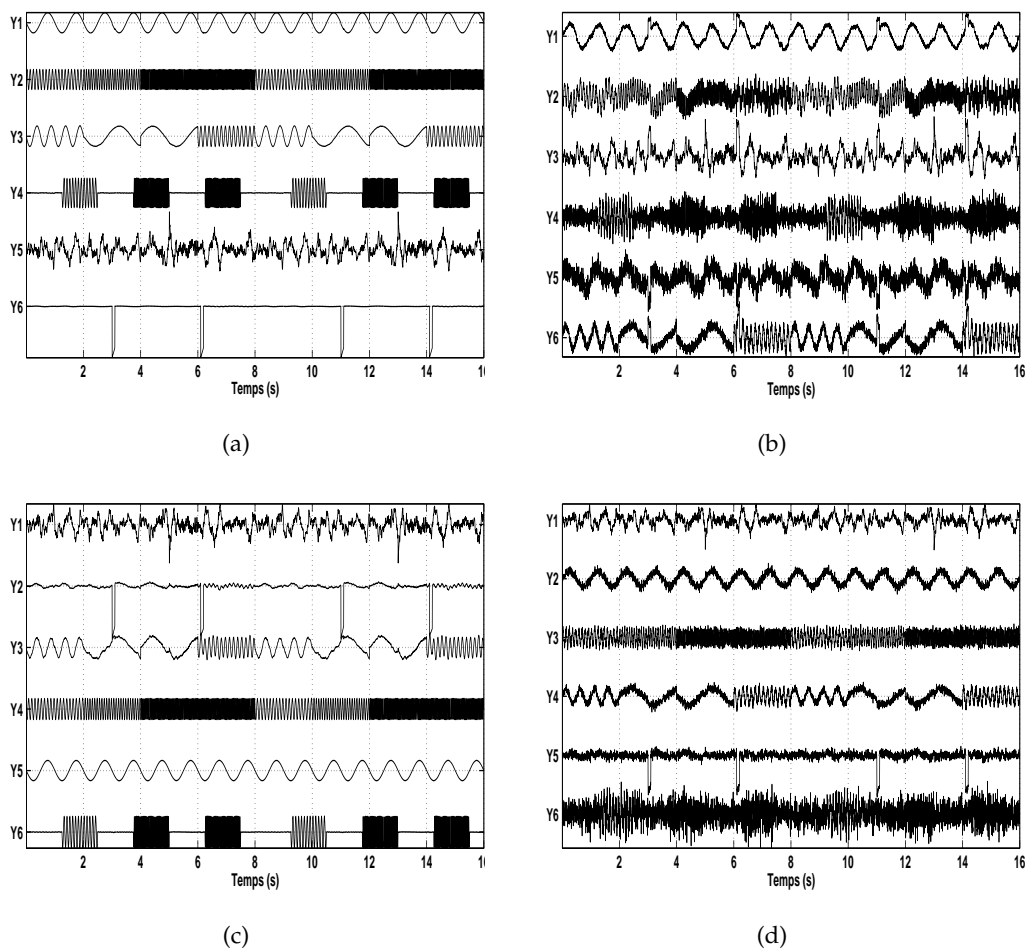
SNR		5 dB		10dB		15dB		20dB	
		$\mu_{IS}$	$\sigma_{IS}$	$\mu_{IS}$	$\sigma_{IS}$	$\mu_{IS}$	$\sigma_{IS}$	$\mu_{IS}$	$\sigma_{IS}$
1	MULTICOMBI	0.1945	0.0493	0.1692	0.0442	0.1489	0.0425	0.1232	0.0425
2	COMBI	0.1906	0.0503	0.1628	0.0472	0.1338	0.0435	0.1094	0.0402
3	EFICA	0.1759	0.0424	0.1419	0.0349	0.1214	0.0328	0.1044	0.0323
4	SEONS	0.1332	0.0410	0.1057	0.0398	0.0821	0.0418	0.0636	0.0385
5	SOBI	0.1988	0.0507	0.1642	0.0477	0.1341	0.0423	0.1102	0.0396
6	SOBI-RO	<b>0.1262</b>	0.0401	<b>0.0995</b>	0.0420	<b>0.0776</b>	0.0420	<b>0.0607</b>	0.0360
7	WASOBI	0.2319	0.0486	0.2177	0.0450	0.2041	0.0445	0.1827	0.0461
8	AMUSE	0.3189	0.0563	0.3069	0.0556	0.2775	0.0558	0.2333	0.0572
9	THINICA	0.1864	0.0493	0.1449	0.0402	0.1225	0.0344	0.1082	0.0331

lièrement stable. En moyenne, les algorithmes statistiques d'ordre deux à blanchiment robuste semblent plus performants, surtout SOBI-RO.

A partir des résultats présentés, nous proposons d'employer l'algorithme SOBI-RO pour l'estimation de sources sur les enregistrements d'EEG réels. Ces résultats sont en accord avec plusieurs études [Joyce *et al.*, 2004; Kierkels *et al.*, 2006; Romero *et al.*, 2008] qui indiquent que les algorithmes de SAS basés sur la statistique d'ordre deux sont plus efficaces sur les signaux d'EEG, car les sources électrophysiologiques d'intérêt sont autocorrélées et vérifient les hypothèses de la séparation par la statistique d'ordre deux de type SOBI/ SOBI-RO.

Cependant une deuxième approche est possible : une étape de débruitage pourrait améliorer les résultats des algorithmes sensibles au bruit qui se sont montrés efficaces dans des conditions idéales comme par exemple MULTICOMBI. Selon les résultats des tableaux 2.1 et 2.4, on constate que l'algorithme MULTICOMBI présente le meilleur IS pour l'EEG simulé sans bruit, mais ses performances sont assez faibles pour l'EEG simulé bruité. Les figures 2.14(a) et 2.14(b) illustrent un exemple de ce phénomène. Pour les mêmes configurations, il s'avère que SOBI-RO (figures 2.14(c) et 2.14(d)) se comporte mieux, avec des IS corrects dans les deux modèles d'EEG simulés.

Par conséquent, SOBI-RO et MULTICOMBI ont été testés en combinaison avec des



**FIGURE 2.14.** (a) sources estimées par MULTICOMBI sans bruit ( $IS=0.0167$ ), (b) sources estimées par MULTICOMBI bruitées ( $IS=0.1545$ ), (c) sources estimées par SOBI-RO sans bruit ( $IS=0.0167$ ), (d) sources estimées par SOBI-RO bruitées ( $IS=0.1$ )

algorithmes de débruitage. Les résultats de cette association méthodologique sur signaux simulés sont présentés chapitre 4).

### 2.3.4 Illustration sur signaux EEG réels

De plus, il est clair que malgré nos efforts pour simuler un EEG réaliste, il est possible que certains cas réels soient suffisamment différents pour changer l'ordre des algorithmes (voir les simulations avec matrice inconnue et bruit inconnu, tableau 2.4). Cependant, la validation en simulation est la seule validation objective possible. Nous avons également appliqué les deux algorithmes cités ci-dessus (SOBI-RO et MULTICOMBI) sur des si-

gnaux EEG réels, même s'il est clair qu'il n'est pas possible d'utiliser un critère objectif de type *IS* pour évaluer leur performances et que le choix est difficile et surtout subjectif. Les exemples présentés dans les figures 2.16(a) et 2.16(b) confirment cette difficulté.

Une inspection rapide des résultats nous confirme que la séparation, quel que soit l'algorithme, est efficace pour estimer le signal d'électrocardiogramme (ECG).

En revanche, parmi les sources estimées par l'algorithme MULTICOMBI (figure 2.16(a)), on peut constater deux sources d'artéfacts oculaires similaires alors que l'algorithme SOBI-RO (figure 2.16(b)) estime une seule source de ce type. Dans ce cas, on pourrait conclure que SOBI-RO a mieux séparé l'artéfact oculaire. Cependant, il est aussi possible que cet artéfact soit issu de deux sources (mais quel sens a un modèle à deux sources du point de vue mélange de signaux?), correspondant aux muscles des paupières des deux yeux, auquel cas le raisonnement précédent est faux. D'un autre côté, l'objectif de la séparation est l'identification des sources d'artéfacts afin de les éliminer du mélange reconstruit, donc, dans la mesure où les sources (une pour SOBI-RO, deux pour MULTICOMBI) sont identifiées correctement par l'étape de classification, le résultat final est équivalent. De plus, identifier une seule source comme artéfact oculaire peut favoriser la classification – les caractéristiques risquent d'être plus marquées. Enfin, le risque d'un résultat ambigu et perturbant pour l'interprétation médicale est plus grand si l'on a deux sources d'artéfacts : en effet, si un seul signal est reconnu automatiquement comme source d'artéfacts et qu'il est éliminé du mélange reconstruit, le résultat sera correct pour SOBI-RO, mais des résidus artéfactuels resteront dans le mélange reconstruit après application de MULTICOMBI.

D'autres signaux clairement caractérisés comme perturbations peuvent être identifiés parmi les sources séparées par les deux algorithmes. Par exemple, on peut identifier deux sources d'un artéfact de haute fréquence parmi les sources de SOBI-RO, et trois parmi les sources générées par MULTICOMBI.

La source 24 fournie par SOBI-RO, qui semble être issue de ce type d'artéfact, pourrait en fait être un mélange de plusieurs sources haute fréquence et du bruit mal séparés, ce qui signifierait que la séparation par SOBI-RO est mauvaise. En revanche, en reprenant l'argument précédent, si l'objectif est la classification des sources, il est très probable que cette source soit reconnue et classée facilement comme une perturbation à la fois par les experts cliniques et par les algorithmes de classification automatique, et que les trois sources de MULTICOMBI soient plus ambiguës.




FIGURE 2.15. EEG brut perturbé par artéfacts

## 2.4 Conclusion


Ce chapitre présente de nombreux résultats générés par la simulation. Cette étape peut paraître lourde et fastidieuse et même incomplète. Toutefois, elle nous a semblé nécessaire à plusieurs titres :

- Il n'existe pas actuellement dans la littérature de travaux publiés comparant objectivement l'efficacité des différents algorithmes de séparation de sources lorsqu'ils sont appliqués sur des signaux EEG, simulés ou réels ;
- Il est difficile de valider les hypothèses d'applicabilité des différents algorithmes sur les signaux EEG, et la seule possibilité reste une simulation des sources et du mélange ;
- En ce qui concerne la simulation des EEG, l'obtention d'une simulation réaliste est délicate, car c'est difficile de mesurer ou d'évaluer la stationnarité des processus de génération, de perturbations et du bruit du système.


L'objectif de cette partie est donc de quantifier l'efficacité des différents algorithmes en fonction d'un certain nombre de paramètres tout à fait maîtrisés dans une phase de simulation. Il est à noter que le modèle de mélange additif instantané n'a pas été remis en cause au cours de cette phase. En effet, l'objectif de la méthodologie développée est de

permettre le prétraitement des EEG de surface, en particulier l'élimination des artéfacts. L'introduction de modèles de mélange plus complexes tels que des mélanges convolutifs ou des modèles de connaissances aurait largement compliqué l'analyse et probablement obscurci l'objectif, d'autant plus que ces modèles, probablement justifiés pour les sources cérébrales, ne le sont pas nécessairement pour les sources d'artéfacts.

En conclusion de ce chapitre, l'algorithme SOBI-RO est donc sélectionné pour l'application sur signaux réels. La difficulté discutée dans le chapitre suivant est d'établir des critères de performances sur ces signaux réels.



(a)



(b)

**FIGURE 2.16.** (a) Sources séparées estimées par MULTICOMBI (b) Sources séparées estimées par SOBI-RO



## Chapitre 3

# Identification automatique de sources d'artéfacts

La première étape de pré-traitement des EEG de surface, décrite et configurée pour notre application dans le chapitre précédent, est la séparation de sources. Le résultat est une décomposition linéaire du signal multivoie d'origine en plusieurs sources, en principe non corrélées (quel que soit le décalage temporel) et donc, dans le paradigme séparation de sources, issues de phénomènes physiques distincts. Dans le cas des signaux EEG, cela signifie que les signaux-source proviennent de structures (cérébrales et/ou extra-cérébrales) distinctes.

Ce point de vue nous permet de reconstruire un signal EEG partiel, en éliminant les sources identifiées comme perturbatrices : les sources identifiées comme artéfacts seront mises à 0 (ou, pour un résultat identique, c'est les colonnes correspondantes de la matrice de mélange estimée par l'algorithme de SAS qui seront mises à 0). L'étape préalable à la construction d'une chaîne de pré-traitement est donc l'identification de ces sources d'artéfacts.

Les premiers travaux décrits dans la littérature proposent une étape d'identification et de classification de sources par inspection visuelle [Vigario, 1997; Jung *et al.*, 2000b]. La procédure est fastidieuse et subjective : les résultats dépendent d'une part de l'expertise de l'examineur, et d'autre part de l'objectif médical qu'il poursuit. Typiquement, si l'objectif médical est l'amélioration de l'analyse ou de la visualisation d'un événement connu, attendu (crise d'épilepsie, potentiel évoqué), l'expert aura tendance à sélectionner les sources d'intérêt, à *garder dans la reconstruction* (*i.e.* celles sur lesquelles on identifie visuellement la forme d'onde recherchée). Au contraire, si l'interprétation de l'EEG est dif-



ficile à cause des perturbations et que les phénomènes recherchés (début de crise, pointe inter-critique) ne sont pas immédiatement visibles, l'expert sera enclin à sélectionner les sources de perturbation à *éliminer de la reconstruction*, afin d'avoir une représentation plus claire de l'EEG et de déceler les rythmes masqués.

Il est donc intéressant de construire une méthode d'identification et d'élimination automatique d'artéfacts (ou alors d'identification automatique des sources d'intérêt). Notre travail vise, dans un premier temps, le pré-traitement des EEG de surface pour améliorer leur interprétation : en d'autres termes, notre objectif est l'identification automatique des artéfacts.

Différentes méthodes d'élimination automatique d'artéfacts ont été proposées dans la littérature. Une des possibilités, proposée récemment par plusieurs auteurs, est d'intégrer l'étape d'identification et élimination directement dans la séparation-décomposition linéaire des signaux mesurés : des sous-espaces séparés sont créés pour les sources cérébrales et pour les sources d'artéfacts, en fonction typiquement des valeurs propres des matrices de covariance. Parmi ces méthodes de sous-espaces, on peut citer par exemple Boudet *et al.*, 2007; Teixeira *et al.*, 2006. De par leur nature, ces méthodes n'intègrent pas directement l'expertise médicale même si celles ci sont basées sur une validation *a posteriori*.

Nous adoptons ici un autre point de vue : après séparation, les sources sont classées par une méthode basée explicitement sur les connaissances des experts neurologues. Deux grandes familles de méthodes de classification peuvent être distinguées : le système expert, basé sur de règles de décision, et la classification supervisée, basée sur une analyse probabiliste/ statistique. Les deux méthodes impliquent une description des sources en fonction des caractéristiques significatives du point de vue médical, suivie d'une formalisation algorithmique de cette description.

### 3.1 Classification des sources EEG : état de l'art

Dans la littérature, la plupart des méthodes d'identification automatique se concentrent sur l'identification de l'artéfact oculaire, soit en exploitant l'électro-oculogramme (EOG) comme signal de référence soit en extrayant des caractéristiques temporelles, spatiales et fréquentielles des sources [Wallstrom *et al.*, 2004; Joyce *et al.*, 2004; Krishnaveni *et al.*, 2006; Li *et al.*, 2006; Nicolaou et Nasuto, 2007; Romero *et al.*, 2008]. Ces méthodes sont généralement calibrées et adaptées pour identifier les artéfacts oculaires parmi les sources et elles ne sont donc pas directement extensibles à d'autres

types d'artéfacts (caractéristiques différentes).

D'autres auteurs proposent des méthodes d'élimination complète d'artéfacts, qui peuvent être, comme dans le cas des artéfacts oculaires, soit basées sur des signaux de référence soit sur un jeu plus complet de caractéristiques. Par exemple, James et Gibson, 2003 proposent un algorithme d'ICA sous contraintes en utilisant des signaux de référence, dont l'enregistrement est synchronisée avec l'EEG. Plus récemment Greco *et al.*, 2006, Ting *et al.*, 2006 et LeVan *et al.*, 2006 proposent des méthodes de classification de sources<sup>7</sup> basées sur des caractéristiques temporelles, fréquentielles et spatiales et sur des règles de décision (le choix des seuils est crucial pour éviter l'élimination de sources informatives) pour les deux premières citations et sur une classification supervisée par analyse discriminante (règles de Bayes) pour la dernière contribution. Ces méthodes aboutissent à une partition des sources en 2 classes : sources informatives (cérébrales) et artéfacts (extra-cérébrales).

En général, toutes les méthodes de classification sont construites en deux étapes : l'extraction de caractéristiques des sources (la similarité avec un signal de référence peut être vue, après quantification, comme une caractéristique), suivie de l'application d'un algorithme de prise de décision (système expert ou classification statistique).

### 3.1.1 Extraction des caractéristiques

La séparation de sources estime les sources et la matrice de mélange. Les deux peuvent être exploitées pour l'extraction des caractéristiques, car chaque source peut être décrite à la fois par ses caractéristiques intrinsèques (contenu fréquentiel, propriétés statistiques, corrélation avec une référence, etc) et par sa façon de participer au mélange (caractéristiques de la colonne correspondante de la matrice de mélange). Ces variables explicatives constituent l'espace de représentation. Donc, chaque source est représentée par un vecteur de caractéristiques dans l'espace de représentation, l'ensemble des vecteurs constituant une matrice de données (chaque ligne correspond à une source, chaque colonne à une caractéristique).

Dans la littérature, plusieurs méthodes basées sur différentes caractéristiques ont été proposées afin de classer les sources estimées d'EEG de façon automatique en sources d'artéfacts ou sources informatives.

Les caractéristiques utilisées par ces méthodes sont :

- **Caractéristiques statistiques**, comme le kurtosis et l'entropie. Le kurtosis est utilisé

---

7. Les algorithmes de séparation utilisés sont respectivement Infomax, AMUSE et FASTICA

pour détecter les activités spécifiques dans certains types d'artéfacts (*i.e.* artéfacts oculaires et cardiaques). L'entropie vise le même objectif : elle aide à l'identification des signaux qui sont concentrés sur de faibles intervalles de temps, avec une haute probabilité, lesquels sont potentiellement des artéfacts [Delorme *et al.*, 2001; Greco *et al.*, 2006]<sup>8</sup>.

- **Similarité avec des signaux de référence** : lorsque les signaux possèdent une morphologie particulière, un signal modèle des différents artéfacts est utilisé comme référence (*i.e.* électro-oculogramme (EOG), électrocardiogramme (ECG)) [LeVan *et al.*, 2006; Wallstrom *et al.*, 2004; Joyce *et al.*, 2004; James et Gibson, 2003; Li *et al.*, 2006; Nicolaou et Nasuto, 2007]. Les signaux similaires sont identifiés par corrélation<sup>9</sup>.
- **Caractéristiques fréquentielles** : les sources sont caractérisées par leur énergie dans les différents bandes de fréquence électrophysiologiques [LeVan *et al.*, 2006; Ting *et al.*, 2006; Romero *et al.*, 2008].
- **Caractéristiques spatiales** : le système de mélange est à la base de ce type de caractéristiques, lié à la topographie cérébrale [Romero *et al.*, 2008; Li *et al.*, 2006; Ting *et al.*, 2006]. En principe, l'hypothèse de base est que la puissance (et donc les coefficients du mélange) de la projection des sources sur le scalp dans le repère anatomique permet l'analyse de son origine physiologique.

### 3.1.2 Classification

Après l'extraction des caractéristiques, chaque source devient un point dans un espace de caractéristiques de dimension  $d$ . Le but de la classification est de déterminer des "frontières" dans cet espace pour séparer les différents types de signaux (artéfacts oculaires, haute fréquence, d'ECG et les sources cérébrales informatives).

Dans la littérature, un grand nombre de méthodes de classification ont été proposés : les réseaux de neurones artificiels, des méthodes de classification non supervisées (*clustering*), des systèmes à base de règles (systèmes experts), des méthodes d'analyse discriminante, *etc.*

En ce qui concerne les signaux EEG et, plus particulièrement, la classification de sources d'artéfacts, les systèmes à base de règles avec des seuils prédéterminés en fonction de l'expertise médicale constituent la technique la plus utilisée [Joyce *et al.*, 2004;

---

8. Une approche basée sur la même hypothèse – changement de variance dans le temps, est proposée par [Boudet *et al.*, 2007]

9. Les signaux de référence peuvent être aussi utilisés par des algorithmes de SAS sous contrainte [James et Gibson, 2003].

Li *et al.*, 2006; Wallstrom *et al.*, 2004; Ting *et al.*, 2006; Romero *et al.*, 2008; Greco *et al.*, 2006]. D'autres méthodes ont également été exploitées : les réseaux de neurones [Krishnaveni *et al.*, 2006], les méthodes de *clustering* [Nicolaou et Nasuto, 2007] et l'analyse discriminante [LeVan *et al.*, 2006].

Pour identifier les artéfacts, nous nous sommes inspirés de 3 méthodes de classification : un système expert et deux méthodes de classification probabiliste/ statistique : l'analyse discriminante quadratique (classificateur de Bayes) et sa version simplifiée, la distance de Mahalanobis.

### 3.1.2.1 Système expert

Les systèmes experts codent et exploitent les connaissances et le savoir-faire d'un expert [Ganascia, 1993]. Ainsi, un système expert a pour fonction l'analyse et la reproduction du raisonnement humain dans des domaines particuliers de la connaissance et de la décision grâce à l'exploitation d'un certain nombre de connaissances fournies explicitement par des experts du domaine. Un système expert permet de modéliser le raisonnement d'un expert, de manipuler des connaissances sous une forme déclarative, d'en faciliter l'acquisition, la modification et la mise à jour et de produire des explications sur la façon dont sont obtenus les résultats d'une expertise.

### 3.1.2.2 Classification supervisée

Les méthodes de classification supervisée sont basées sur une classification *a priori* des données, faite par des experts, pour construire un ensemble d'apprentissage. Après apprentissage, tout nouveau signal (point dans l'espace des caractéristiques) sera classé dans une des classes d'apprentissage en minimisant un critère d'appartenance. Une méthode courante est l'analyse discriminante.

Soit  $C_j$  ( $j = 1 \dots k$ ) un ensemble de classes défini *a priori* par des experts. L'analyse discriminante cherche à attribuer un signal  $\mathbf{sf}$  (vu comme un vecteur de variables explicatives  $\mathbf{sf}_i$ , avec  $i = 1 \dots d$ ,  $d$  étant la dimension de l'espace de caractéristiques) à la classe la plus probable.

Pour un signal  $\mathbf{sf}$ , la probabilité d'appartenance à la classe  $C_j$  (la probabilité *a posteriori* de la classe  $C_j$  sachant  $\mathbf{sf}$ ) s'écrit (règle de Bayes) :

$$p(C_j|\mathbf{sf}) = \frac{p(\mathbf{sf}|C_j)p(C_j)}{p(\mathbf{sf})}, \text{ avec}$$

$$p(\mathbf{sf}) = \sum_{j=1}^k p(\mathbf{sf}|C_j)p(C_j), \quad (3.1)$$

où  $p(\mathbf{sf}|C_j)$  est la probabilité de  $\mathbf{sf}$  sachant  $C_j$  (c'est-à-dire la probabilité *a priori* d'appartenance à la classe  $C_j$ ).  $p(C_j)$  est la probabilité *a priori* de la classe  $C_j$ , et  $p(\mathbf{sf})$  la probabilité sur l'ensemble des classes. Attribuer l'appartenance de  $\mathbf{sf}$  à une classe revient à choisir la classe  $C_j$  qui assure une probabilité *a posteriori*  $p(C_j|\mathbf{sf})$  maximale, ce qui revient à maximiser la fonction  $g(\mathbf{sf}, C_j)$  selon  $j$  :

$$g(\mathbf{sf}, C_j) = p(\mathbf{sf}|C_j)p(C_j),$$

ou encore, à maximiser  $l(\mathbf{sf}, C_j)$  :

$$l(\mathbf{sf}, C_j) = \ln(g(\mathbf{sf}, C_j)) = \ln p(\mathbf{sf}|C_j) + \ln p(C_j). \quad (3.2)$$

En considérant des classes gaussiennes  $C_j$  de moyenne  $\mu_j$  et matrices de covariance  $\Sigma_j$ , la probabilité *a priori*  $p(\mathbf{sf}|C_j)$  s'écrit :

$$p(\mathbf{sf}|C_j) = \frac{1}{(2\pi)^{d/2}|\Sigma_j|^{1/2}} \exp \left[ -\frac{1}{2}(\mathbf{sf} - \mu_j)^T \Sigma_j^{-1}(\mathbf{sf} - \mu_j) \right], \quad (3.3)$$

L'appartenance d'un vecteur  $\mathbf{sf}$  à une classe spécifique  $C_j$  se décide en maximisant (3.2), donc en minimisant

$$-l(\mathbf{sf}, C_j) = \frac{1}{2}(\mathbf{sf} - \mu_j)^T \Sigma_j^{-1}(\mathbf{sf} - \mu_j) + \frac{1}{2} \ln |\Sigma_j| - \ln p(C_j), \quad (3.4)$$

En pratique, la moyenne et la matrice de variance-covariance sont estimées à partir des individus déjà classés (c'est-à-dire sur les classes d'apprentissage).

Souvent, la probabilité *a priori* est considérée la même pour toutes les classes. En considérant cela et en ignorant aussi le terme de normalisation  $\frac{1}{2} \ln |\Sigma_j|$ , la grandeur à minimiser devient :

$$d(\mathbf{sf}, C_j) = \frac{1}{2}(\mathbf{sf} - \mu_j)^T \Sigma_j^{-1}(\mathbf{sf} - \mu_j) \quad (3.5)$$

Dans ce cas, le critère (3.5), calculé pour chaque nouvel individu à classer et pour chaque classe, est assimilé à une distance entre cet individu et les barycentres (distance de Mahalanobis).

Dans cette thèse, nous avons utilisé deux méthodes d'analyse discriminante : la classification de Bayes (analyse discriminante quadratique, équation 3.4) et la distance de Mahalanobis (équation 3.5).

## 3.2 Classification des sources EEG : mise en œuvre

Cette section est dédiée principalement à la description de notre méthodologie de classification des signaux EEG mesurés. Cependant, avant de détailler cette implémentation, il est nécessaire de s'attarder sur les étapes qui la précèdent : la séparation de sources, telle que décrite dans le chapitre précédent, ne prend pas en compte les problèmes liés à l'acquisition du signal et plus particulièrement les problèmes de type de montage et de références. Ces aspects seront donc abordés dans une première sous-section.

Quant aux sous-sections suivantes, elles apportent des précisions sur l'implémentation des méthodes de classification sur les signaux réels. En ce qui concerne la classification, nous nous sommes efforcés d'exploiter des caractéristiques décrites par les experts comme étant pertinentes. L'ensemble d'apprentissage permet d'effectuer la validation des paramètres libres pour l'extraction des caractéristiques. L'essentiel de la section suivante est donc constitué par la présentation et la discussion de ces choix *a priori*. La validation finale de la méthodologie fera l'objet de la dernière section 3.4, les résultats sur une base de données d'EEG réels seront présentés.

### 3.2.1 Acquisition d'EEG

#### 3.2.1.1 Montage d'acquisition

Plusieurs montages sont utilisés pour construire un EEG. Dans la plupart des cas (voir chapitre 1), l'acquisition est faite en montage référentiel, les autres dérivations (bipolaire, référentiel moyen) étant obtenues par des manipulations simples (soustraction deux à deux, soustraction d'une moyenne commune). Le rôle de ces différents montages est de faciliter l'interprétation médicale, de permettre des points de vue complémentaires sur l'activité électrique. Un bénéfice important des montages bipolaire ou référentiel moyen est d'atténuer considérablement l'influence de l'électrode de référence : effectivement, grâce aux soustractions mentionnées ci-dessus, le potentiel électrique de cette électrode disparaît du montage. En revanche, le montage bipolaire, comme le montage référentiel moyen, réduisent le nombre de degrés de liberté du problème : les mesures générées par

ces montages ne sont plus linéairement indépendantes, le rang de la matrice de mélange se retrouve réduit et de fait le nombre de sources possibles à estimer (voir [Salido-Ruiz *et al.*, 2009] pour une discussion sur le rôle du montage dans la séparation des sources EEG).

La solution que nous avons adoptée pour ne pas diminuer la dimension du problème est donc d'appliquer la séparation de sources sur le montage d'acquisition, en référence commune. Ce choix a une influence importante sur la matrice de mélange estimée et, par conséquent, sur les caractéristiques spatiales des sources.

### 3.2.1.2 Durée d'acquisition

Comme expliqué précédemment (section 2.2.2), une séparation de sources fiables nécessite un nombre de points relativement important, donc une durée suffisamment longue. Dans la littérature dédiée spécifiquement aux EEG, peu de références mentionnent explicitement une durée optimale. En principe, ce nombre minimal de points est proportionnel au carré du nombre de voies  $Q$  ( $Q=24$  donc  $Q^2=576$  échantillons) [Delorme et Makeig, 2004], mais le coefficient de proportionnalité est assez variable selon les auteurs et dépend du nombre d'électrodes, ainsi que de l'algorithme de séparation choisi (SOS versus HOS) :  $5 \times Q^2$ ,  $7 \times Q^2$ ,  $25 \times Q^2$ ,  $30 \times Q^2$ , avec en principe moins de points pour les algorithmes basés sur des statistiques d'ordre deux (SOS) [Särelä et Vigario, 2003; Gómez-Herrero *et al.*, 2005; Onton et Makeig, 2006; Delorme et Makeig, 2009; Joyce *et al.*, 2004].

Selon l'application, le nombre maximal (taille maximale de la fenêtre) est limité par des contraintes de stationnarité nécessaires à la fois pour la SAS et pour la classification. Physiologiquement, une fenêtre de 20 secondes d'EEG peut être considérée relativement stationnaire [Mocks et Gasser, 1984]. Nous avons donc limité la taille de notre fenêtre d'analyse à 20 secondes (5120 échantillons), ce qui correspond à  $\approx 10 \times Q^2$ .

### 3.2.1.3 Elimination de la ligne de base

L'élimination des fluctuations de la ligne de base est indispensable et elle fait partie de la chaîne de traitement classique des EEG. Elle peut être implémentée directement dans l'instrumentation (filtre passe-haut lors de l'acquisition) ou comme première étape de traitement. Son objectif est d'éliminer les artéfacts de basse fréquence (*i.e.* dérives électriques, mouvements oculaires lents, ...) qui peuvent perturber l'interprétation mais aussi la séparation et la classification de sources.

Dans notre cas, les signaux ne sont pas filtrés passe-haut à l'acquisition, et nous avons choisi de les traiter par un filtrage après décomposition en ondelettes. Dans le contexte de cette thèse, qui vise à combiner séparation de sources et débruitage (voir chapitre suivant 4), cette implémentation est la plus naturelle. Il est néanmoins clair que le résultat est similaire à celui obtenu plus directement par filtrage passe-haut classique.

Etant donné la fréquence d'échantillonnage utilisée (256 Hz), nous avons fait une décomposition en ondelettes de profondeur  $D=7$  pour chaque voie d'EEG enregistrée (voir explications plus détaillées sur la décomposition en ondelettes dans le chapitre 4). Les coefficients d'approximation ont été annulés et les signaux ont été reconstruits à partir des détails uniquement. Par conséquent, les coefficients de la bande spectrale correspondant à l'échelle d'approximation ( $< 1$  Hz) ont été éliminés. Les figures 3.1(a) et 3.1(b) présentent un exemple sur une durée de 20 secondes d'EEG en montage référentiel commun (électrode de référence FPz), avant et après élimination de la ligne de base. Le même tracé, en montage bipolaire, est présenté dans la figure 3.1(c).

### 3.2.2 Extraction des caractéristiques


Afin d'identifier les sources d'artéfacts après l'analyse des résultats de la SAS, plusieurs ensembles de caractéristiques ont été testés et nous avons décidé d'utiliser une combinaison de caractéristiques spatiales (topographiques), fréquentielles et de similarité avec des signaux de référence.

#### 3.2.2.1 Caractéristiques spatiales


Un signal EEG en référentiel commun est la mesure de la différence de potentiel entre deux électrodes (une électrode quelconque présente sur le scalp et l'électrode définie comme référence). Par conséquent l'électrode de référence joue un rôle très important dans les coefficients de la matrice de mélange, car elle est présente sur l'ensemble des mesures.

Les EEGs utilisés dans cette thèse ont été enregistrés avec l'électrode de référence placée près des yeux (électrode FPz dans le système 10–20, voir figure 1.14). Par conséquent, il y a une forte présence des artéfacts oculaires sur toutes les mesures.

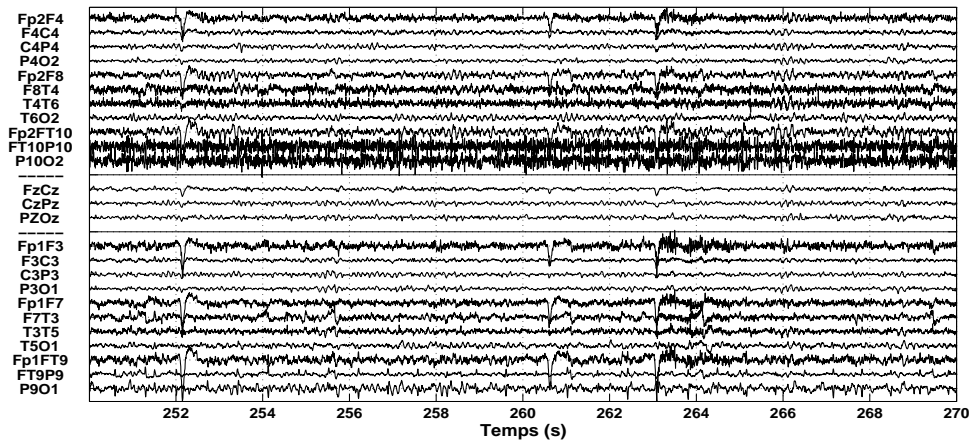




(a) EEG brut, montage référentiel commun



(b) EEG filtré, montage référentiel commun



(c) EEG filtré, montage bipolaire longitudinal

FIGURE 3.1. EEG avant et après l'élimination de la ligne de base : montage référentiel et bipolaire.

Comme indiqué précédemment, après la séparation, les sources sont normalisées (de variance = 1) et la forte présence d'une source sur les signaux mesurés se traduit par une valeur absolue importante des coefficients qui correspondent à cette source dans la matrice de mélange. Par conséquent, la puissance et la propagation spatiale de chaque source peuvent être évaluées à travers la matrice de mélange, particulièrement par les éléments de la colonne de la matrice de mélange correspondante. En ce qui concerne la source d'artéfact oculaire, la colonne correspondante devrait avoir des valeurs significativement plus élevées (car cette source est très présente et en général présente une forte amplitude) et plus constantes (car plus distribuées par le biais de la référence que les autres sources). Évidemment, dans les enregistrements d'EEG réels, la matrice de mélange est inconnue, mais elle est estimée par l'algorithme de séparation  $\hat{\mathbf{A}} = \mathbf{B}^{-1}$  (avec  $\mathbf{B}$  la matrice de séparation). En utilisant la matrice estimée  $\hat{\mathbf{A}}$ , il est possible d'évaluer la contribution d'une source estimée  $y_j$  dans le mélange en calculant la moyenne  $\bar{a}_j$  des valeurs absolues des coefficients de la colonne  $\hat{\mathbf{a}}_j$ .

$$\bar{a}_j = \frac{1}{Q} \sum_{i=1}^Q |\hat{a}_{ij}| \quad j = 1, 2, \dots, Q \quad (3.6)$$

où  $\hat{a}_{ij}$  est l'élément estimé de la  $i^{\text{ième}}$  ligne et la  $j^{\text{ième}}$  colonne de  $\hat{\mathbf{A}}$ .

Pour déterminer la propagation d'une source et en particulier pour évaluer si la source se projette d'une manière pseudo-similaire sur toutes les électrodes (*i.e.* elle est proche de la référence), on peut calculer l'écart-type (normalisé)  $\bar{\sigma}_j$  de chaque colonne  $\hat{\mathbf{a}}_j$ .

$$\bar{\sigma}_j = \frac{\sigma_j}{\bar{a}_j} = \frac{\frac{1}{Q} \sum_{i=1}^Q (a_{ij} - \bar{a}_j)^2}{\bar{a}_j} \quad (3.7)$$

### 3.2.2.2 Similarité avec des signaux de référence

Si, par le protocole d'acquisition, on dispose de signaux extra-cérébraux (tels que les artéfacts, du point de vue de l'interprétation) enregistrés simultanément avec l'EEG, on peut mesurer leur similarité avec les sources séparées à travers le coefficient de corrélation. Soit *ref* ce signal extra-cérébral de référence, la corrélation avec une source  $y_j$  s'écrit :

$$\rho_{ref,j} = \frac{\text{cov}(ref, y_j)}{\sigma_{ref} \sigma_{y_j}} \quad (3.8)$$

En pratique, nous disposons de l'ECG, acquit de manière synchrone avec les données EEG.

### 3.2.2.3 Caractéristiques fréquentielles

Une analyse spectrale a été réalisée pour toutes les sources estimées. L'énergie des 5 bandes de fréquence électrophysiologiques de chaque source  $y_j$  a été calculée, les résultats étant notés  $E_{\delta_j}$ ,  $E_{\theta_j}$ ,  $E_{\alpha_j}$ ,  $E_{\beta_j}$  et  $E_{\gamma_j}$  (voir le chapitre 1 pour la définition des bandes de fréquence). Pour s'affranchir des variations dues aux éventuels gains entre les voies ou entre les patients, ces énergies ont été normalisées en utilisant l'énergie totale  $E_{t_j}$  (intervalle de fréquence totale 1 - 128Hz). Les caractéristiques obtenues sont  $\bar{E}_{\delta_j}$ ,  $\bar{E}_{\theta_j}$ ,  $\bar{E}_{\alpha_j}$ ,  $\bar{E}_{\beta_j}$  et  $\bar{E}_{\gamma_j}$ . En raison de cette normalisation, les 5 caractéristiques fréquentielles ne sont plus indépendantes, donc seules 4 d'entre elles peuvent être considérées, :  $\bar{E}_{\delta_j}$ ,  $\bar{E}_{\alpha_j}$ ,  $\bar{E}_{\beta_j}$  et  $\bar{E}_{\gamma_j}$ .

Pour chaque source estimée, la fréquence principale  $f_{m_j}$  (estimée à partir de la valeur maximale de la densité spectrale de puissance) a été également calculée.

Au final, chaque source estimée  $y_j$  est caractérisée par 8 caractéristiques : 5 caractéristiques fréquentielles ( $\bar{E}_{\delta_j}$ ,  $\bar{E}_{\alpha_j}$ ,  $\bar{E}_{\beta_j}$ ,  $\bar{E}_{\gamma_j}$  et  $f_{m_j}$ ), 2 caractéristiques spatiales ( $\bar{\sigma}_j$  et  $\bar{a}_j$ ) et 1 caractéristique de similarité avec un signal de référence en l'occurrence l'ECG ( $\rho_{ecg,j}$ ).

Ces caractéristiques extraites visent à coder et quantifier les critères exploités de façon subjective par les neurophysiologistes. L'espace des caractéristiques étant défini, l'étape suivante concerne la classification.

### 3.2.3 Classification

Comme il a été indiqué précédemment, pour les méthodes de classification guidées par l'expertise médicale, il est nécessaire de formaliser la procédure d'évaluation des caractéristiques selon certaines règles.

Soit cette formalisation peut être explicite, sous forme de règles de décision (par exemple, si la caractéristique  $V$  dépasse un certain seuil, alors la source est un artéfact de type  $AX$ ), et, dans ce cas, on aboutit à la construction d'un système expert. Soit la formalisation peut être implicite : les sources sont regroupées par les experts dans un ensemble de groupes homogènes selon l'espace des caractéristiques définis. Dans ce cas, cet ensemble dit d'apprentissage doit contenir un nombre suffisant, statistiquement représentatif s'entend, de candidats par classe pour contribuer à la classification supervisée.

Dans les deux cas, dans le cadre de la supervision, les experts doivent analyser les sources séparées. Les cliniciens possèdent une grande expérience dans l'examen des rythmes cérébraux et dans l'identification de *patterns* d'artéfacts sur les signaux d'EEG. Bien que ils ne soient pas familiarisés avec une analyse visuelle de sources intra-cérébrales

estimées par les algorithmes de SAS, ils peuvent identifier les sources des artéfacts en reconnaissant la présence de *patterns* et en mesurant leur évolution temporelle avec les enregistrements d'EEG (montages bipolaires et référentiels). Nous avons donc demandé aux experts cliniques d'identifier les artéfacts oculaires (AO), artéfacts d'ECG (AECG), les artéfacts musculaires de haute fréquence (AHF) ainsi que les sources cérébrales, c'est-à-dire les sources non contaminées par des artéfacts (B) parmi les sources estimées. Comme il est de grande importance de ne pas perdre d'information potentiellement utile pour l'interprétation et le diagnostic médical, et que certaines sources sont difficiles à apprécier, les experts cliniques ont choisi uniquement les sources d'artéfacts pour lesquelles il n'y avait aucune ambiguïté d'appréciation. Ce parti pris est particulièrement appréciable pour la construction de l'ensemble d'apprentissage (les groupes sont de fait très homogènes) ou pour formaliser les règles de décision du système expert. Cependant, comme on le verra lors de l'analyse des résultats, si cet ensemble est utilisé comme base de comparaison pour les algorithmes automatiques (*golden standard*), il risque de biaiser les résultats. Ce dernier aspect sera détaillé et discuté dans la sous-section suivante.

La figure 3.2 présente les sources obtenues après séparation et leur classification par les experts cliniques après l'étude comparative des tracés des sources et des EEG sans ligne de base, en montages référentiel commun et bipolaire (figure 3.1(b) et 3.1(c)).

La figure 3.2 présente également le contenu fréquentiel des sources estimées.


### 3.2.3.1 Système expert

Nous avons développé un système expert pour l'identification des artéfacts en utilisant les caractéristiques spatiales de similarité avec des signaux de référence et fréquentielles. Ce système est basé sur des règles de décision spécifiques qui procèdent de l'expertise médicale. Ces règles de décision, pour chaque type d'artéfact, sont décrites dans les paragraphes suivants.

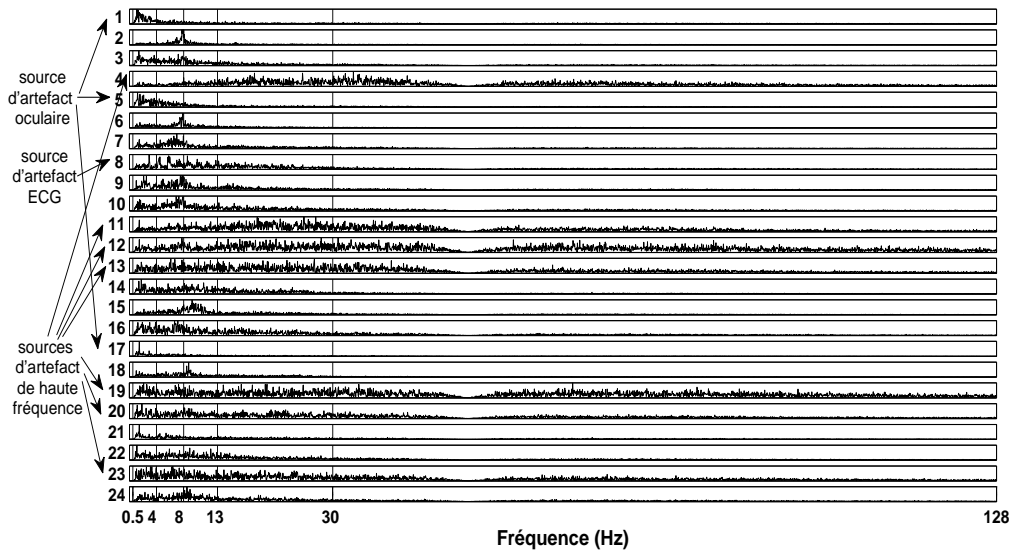
**Artéfact oculaire – AO.** Comme il a été mentionné précédemment, les caractéristiques spatiales sont influencées par l'électrode de référence. Si l'électrode de référence est différente de FPz (et par conséquent moins contaminée par les artéfacts oculaires), l'EEG doit être re-référencé à l'électrode FPz avant d'appliquer la méthode que nous proposons ici.

Trois caractéristiques ont été utilisées pour l'identification de l'AO :  $\bar{a}_j$ ,  $\bar{\sigma}_j$  et  $\bar{E}_{\delta_j}$ . Une source  $y_j$  est identifiée comme un artéfact oculaire si elle respecte les trois règles suivantes :

- La source contamine fortement les mesures des électrodes (*i.e.* elle a la valeur maxi-



(a) Sources



(b) Spectres

FIGURE 3.2. Sources estimées par SOBI-RO et leur classification par les experts : tracé temporel et fréquentiel

male pour  $\bar{a}_j$  (3.6) ( $\bar{a}_j > \bar{a}_i \forall i \neq j$ ).

– La source est proche du signal de référence (la propagation sur toutes les électrodes

est similaire, c'est-à-dire  $\bar{\sigma}_j$  est la plus petite ( $\bar{\sigma}_j < \bar{\sigma}_i \forall i \neq j$ ).

- L'énergie de la source dans les basses fréquences est plus grande que pour les autres bandes de fréquence ( $\bar{E}_{\delta_j} > \bar{E}_{\alpha_j, \beta_j, \gamma_j}$ ).

**Artéfact de haute fréquence – AHF.** Ce type d'artéfact contient essentiellement les artéfacts musculaire et du bruit. L'essentiel de l'information cérébrale observée dans l'EEG de surface est compris dans l'intervalle de 0.5 – 30 Hz. De plus, les activités épileptiques du lobe temporal sont elles aussi principalement dans cette gamme de fréquences (plus précisément dans la bande  $\theta$  [4 - 8 Hz]). Par conséquent, on considère l'activité dans les bandes de fréquence supérieure à 30 Hz (bande  $\gamma$ ) comme non informative (essentiellement du bruit). De plus, l'activité musculaire est caractérisée par la présence des hautes fréquences, principalement dans la bande  $\beta$  (13 – 30 Hz) [Tran *et al.*, 2004]. Bien que cette hypothèse puisse sembler trop forte dans le cas général, l'objectif de ce travail est de faciliter l'interprétation des EEGs classiques (<30 Hz), utilisés par exemple dans le diagnostic des épilepsies temporales.

Par conséquent pour l'identification de l'artéfact de haute fréquence, deux caractéristiques ont été utilisées  $\bar{E}_{\gamma_j}$  et  $\bar{E}_{\beta_j}$  : une source  $y_j$  est identifiée comme un artéfact de haute fréquence si les deux bandes les plus énergétiques sont  $\bar{E}_{\gamma_j}$  et  $\bar{E}_{\beta_j}$ .

**Artéfact d'ECG** L'électrocardiogramme (ECG) est normalement enregistré simultanément avec l'EEG. Cet enregistrement est inclus dans le protocole en routine clinique. Afin d'identifier les sources d'ECG (si elles contaminent l'EEG) la corrélation entre l'ECG enregistré et les sources estimées  $\mathbf{y}$  a été calculée selon (3.8).

Une source  $y_j$  est reconnue comme artéfact ECG si elle est suffisamment corrélée avec le signal d'ECG de référence :  $\rho_{ecg,j} \geq 0.5$ .

### 3.2.3.2 Classification

La classification a été implémentée selon la description faite dans la sous-section précédente. L'ensemble d'apprentissage a été construit à partir des sources classées par les experts cliniques après analyse d'une base de données de 38 enregistrements d'EEG. Deux méthodes d'analyse discriminante ont été utilisées : la classification de Bayes et la distance de Mahalanobis.

### 3.3 Validation

Les résultats fournis par les algorithmes de classification (et donc implicitement par la séparation de sources préalable) nécessitent une validation détaillée, sans laquelle toute application clinique est inenvisageable.

Deux grandes familles de méthodes de validation peuvent être identifiées :

1. Une validation **quantitative**, qui mesure l'adéquation des résultats par rapport à un *golden standard* défini par les experts. Dans la mesure où ce standard est parfaitement validé, ce type de critère est objectif. Il peut se décliner de trois manières :
  - un signal (une source) est correctement identifié comme artéfact ou comme signal informatif s'il est similaire à un signal prédéfini (considéré comme une référence), au sens d'une mesure de type erreur quadratique moyenne (EQM), SNR (rapport signal sur bruit/artéfact). Ce type de validation peut être appliqué si l'on dispose d'un tel signal (mesure d'électrooculogramme EOG, potentiels évoqués moyennés, ...) [Jung *et al.*, 2000b; Wallstrom *et al.*, 2004; Romero *et al.*, 2008; Li *et al.*, 2006; Nicolaou et Nasuto, 2007; Kierkels *et al.*, 2006].
  - une source est correctement identifiée si elle a des caractéristiques connues *a priori*. Typiquement, ce type de validation s'applique aux artéfacts oculaires, qui influencent surtout les électrodes proches des yeux et qui ont donc une projection sur le scalp spécifique (éventuellement après filtrage par bande de fréquence physiologique) [Romero *et al.*, 2008; James et Gibson, 2003; Jung *et al.*, 2000b];
  - enfin, une source est correctement identifiée si elle est proche d'une "source moyenne" au sens de ses caractéristiques décrites précédemment (variables explicatives), autrement dit si elle se trouve, dans l'espace de caractéristiques, dans le voisinage (défini par la matrice de covariance) de cette source moyenne (barycentre) [LeVan *et al.*, 2006; Krishnaveni *et al.*, 2006]. Les matrices de covariance et les barycentres des différentes classes (*i.e.* les sources de référence) sont calculés à partir d'une classification médicale définie par l'ensemble d'apprentissage.

Dans tous les cas, après avoir mesuré cette distance (source identifiée – source référence), on peut décider de l'appartenance de cette source à une des classes considérées. En répétant le calcul pour toutes les sources d'un ensemble de test, on peut compter les bonnes/mauvaises classifications et déduire les indices classiques de sensibilité et de spécificité (voir sous-section 3.3.1). Appliquer cette méthode sur l'ensemble d'apprentissage, s'il existe, peut nous renseigner sur sa validité : si les résultats sont nettement meilleurs que sur l'ensemble de test cela implique un sur-

apprentissage : la classification ne peut pas être étendue aux nouvelles sources, car elle est trop adaptée aux sources utilisées comme "référence".

2. Une validation **qualitative**, qui fait appel aux experts pour noter la qualité du résultat par rapport à son utilité clinique. Cette évaluation subjective, médicale (qualité d'interprétation, détection visuelle des artéfacts), a été utilisée par exemple dans [LeVan *et al.*, 2006].

Nous avons choisi deux méthodes de validation, une quantitative et l'autre qualitative. La première vise à évaluer les performances des algorithmes de classification à travers les indices de type sensibilité/ spécificité. Ces indices sont calculés à partir d'une classification dans l'espace des caractéristiques, avec des classes décrites par des barycentres et des dispersions (matrices de covariance) estimés sur un ensemble d'apprentissage défini par les médecins<sup>10</sup>.

La deuxième cherche à quantifier l'utilité clinique à travers une validation médicale. Cette validation est faite à travers des qualificatifs (interprétation plus facile / beaucoup plus facile, etc) que les médecins utilisent pour jauger les performances des algorithmes d'identification automatique, comme expliqué dans la sous-section 3.3.2.

### 3.3.1 Evaluation quantitative

La performance de la classification des sources a été faite à partir des critères classiques de sensibilité ( $Sen$ ) et de spécificité ( $Spe$ ), calculés selon les expressions suivantes (calculées pour chaque classe) :

- $VP_c$  représente le nombre de sources qui appartiennent à la classe  $C$  avec un test positif – vrais positifs (*i.e.* classés par les médecins et détectés par les méthodes automatiques dans la classe  $C$ ). En fonction du type de source, ils seront notés  $VP_{AO}$ ,  $VP_{AHF}$ ,  $VP_{AECG}$ ,  $VP_B$ ).
- $FN_c$  représente le nombre de sources qui appartiennent à la classe  $C$  avec un test négatif – faux négatifs (*i.e.* classés par les médecins dans  $C$  mais mal classés par les méthodes automatiques) :  $FN_{AO}$ ,  $FN_{AHF}$ ,  $FN_{AECG}$ ,  $FN_B$ ).
- $VN_c$  représente le nombre de sources qui n'appartiennent pas à la classe  $C$  avec un test négatif – vrais négatifs (*i.e.* non classés par les médecins dans la classe  $C$  et non classés par les méthodes automatiques) :  $VN_{AO}$ ,  $VN_{AHF}$ ,  $VN_{AECG}$ ,  $VN_B$ ).

10. Nous rappelons que, dans notre cas, nous ne disposons pas des signaux d'EOG, un des objectifs étant de proposer une méthode d'élimination automatique d'artéfacts basée uniquement sur des signaux issus des électrodes utilisées en routine clinique.



- $FP_c$  représente le nombre de sources qui n'appartiennent pas à la classe  $C$  avec un test positif – faux positifs (*i.e.* non classés par les médecins dans la classe  $C$  et mais reconnus par les méthodes automatiques comme  $C$ ) :  $FP_{AO}, FP_{AHF}, FP_{AECG}, FP_B$ .

Ces valeurs ont été calculées par rapport à l'expertise médicale considérée comme *golden standard*.

Une analyse globale (G) a été faite aussi :

$$\begin{aligned} VP_G &= VP_{AO} + VP_{AHF} + VP_{AECG} + VP_B \\ FN_G &= FN_{AO} + FN_{AHF} + FN_{AECG} + FN_B \\ VN_G &= VN_{AO} + VN_{AHF} + VN_{AECG} + VN_B \\ FP_G &= FP_{AO} + FP_{AHF} + FP_{AECG} + FP_B \end{aligned}$$

Ensuite, des valeurs de  $Sen$  et  $Spe$  ont été calculées pour chaque classe et pour l'analyse globale :

$$Sen_c = \frac{VP_c}{VP_c + FN_c} \quad (3.9)$$

$$Spe_c = \frac{VN_c}{VN_c + FP_c} \quad (3.10)$$

Un critère plus facilement interprétable est le taux de faux positifs ( $TFP$ ), calculé à partir de la spécificité :

$$TFP = 1 - Spe \quad (3.11)$$

### 3.3.2 Validation médicale

Les trois méthodes de classification (le système expert, la distance de Mahalanobis et la classification de Bayes) permettent l'identification des sources d'artéfacts et la reconstruction des EEGs "propres", reconstruits à partir des sources d'activité cérébrale seulement (classe  $B$ ). Trois EEGs propres ont été reconstruits (un pour chaque méthode de classification). Un quatrième EEG propre a été reconstruit après l'élimination des sources d'artéfacts identifiées visuellement par les experts (méthode semi-automatique, dans la mesure où elle bénéficie des résultats de séparation de sources, mais la classification reste manuelle). En théorie, cette dernière reconstruction devrait être la meilleure en termes d'utilité clinique et d'élimination d'artéfacts, car elle est basée sur le *golden standard*.

La validation a été faite par les experts en comparant l'amélioration entre l'EEG enregistré brut et chaque EEG propre reconstruit. L'amélioration a été évaluée de deux manières : l'amélioration de l'interprétation physiologique et la performance de l'élimination des artefacts.

Les experts cliniques ont comparé les 5 EEG différents (4 EEG reconstruits et l'EEG enregistré brut), et ils les ont classés en 5 catégories selon leur facilité d'interprétation : 1 extrêmement pire, 2 pire, 3 égal, 4 mieux, 5 beaucoup mieux.

Évidemment, l'EEG enregistré brut a été noté 3. S'il y a une petite perte d'information ou si l'élimination des artefacts est partielle et les artefacts restants (modifiés) continuent de fausser l'interprétation médicale, l'EEG "propre" a été noté 2. Si la perte d'information ou les artefacts restants (modifiés) sont considérables, l'EEG obtenu a été noté 1.

Selon l'élimination des artefacts, les EEGs ont été classés en 3 catégories :

1 aucun artefact éliminé, 2 artefacts éliminés partiellement, 3 aucun artefact visible. La validation médicale a été faite en aveugle de façon consensuelle par deux experts, c'est-à-dire elle a été faite sans aucune connaissance par les experts de la méthode utilisée pour l'identification des sources d'artefacts.

### 3.4 Résultats

**Base de données.** Trente huit EEG de surface de 19 patients épileptiques adultes âgés entre 16 et 51 ans, avec épilepsies temporales ont été enregistrés avec un système Micromed au CHU-Nancy. Deux EEGs ont été enregistrés pour chaque patient avec 24 électrodes placées sur le scalp selon le système international 10-20 avec une référence commune placée proche des yeux, l'électrode FPz. Les signaux enregistrés ont été échantillonnés à 256 Hz et un filtre coupe-bande a été appliqué à 50 Hz. Un des EEGs est un enregistrement en période de sommeil (sans artefacts oculaire et musculaire).

**L'ensemble d'apprentissage et l'ensemble de test.** Par inspection clinique, les experts ont identifié les sources d'artefacts et, par exclusion (sources non-identifiées comme artefacts), les sources cérébrales informatives pour les 38 EEGs (24 sources par EEG).

Les sources de 19 EEGs ont été utilisées pour l'ensemble d'apprentissage pour les méthodes de classification proposées. Les 19 EEGs restants ont été utilisés pour tester la performance de ces méthodes (tableau 3.1).

**TABLE 3.1.** sources d'artéfacts et sources cérébrales

<b>Nombre total de sources</b>	912
<b>sources d'artéfact oculaire</b>	54
<b>sources d'artéfact de haute fréquence</b>	281
<b>sources d'ECG</b>	12
<b>sources cérébrales</b>	565

### 3.4.1 Evaluation quantitative

Les trois méthodes de classification automatiques ont été comparées en utilisant les valeurs de  $Sen$  (équation 3.9) et de  $TFP$  (équation 3.11) pour les deux ensembles (d'apprentissage et de test). Le tableau 3.2 montre la performance globale des 3 méthodes : le système expert, la méthode de la distance de Mahalanobis et le classificateur de Bayes.

**TABLE 3.2.** Les performances globales des 3 méthodes de classification

	<b>Distance de Mahalanobis</b>	<b>Classificateur de Bayes</b>	<b>Système expert</b>
	<b>Ensemble d'apprentissage</b>		
<b><math>Sen_G</math></b>	0.8531	0.8026	0.8311
<b><math>TFP_G</math></b>	0.0490	0.0658	0.0563
	<b>Ensemble de test</b>		
<b><math>Sen_G</math></b>	0.8224	0.7829	0.7719
<b><math>TFP_G</math></b>	0.0592	0.0760	0.0724

D'après le tableau 3.2, on observe que toutes les méthodes sont assez performantes, ce qui constitue en soi une validation de l'ensemble des caractéristiques choisies.

La méthode basée sur la distance de Mahalanobis génère les meilleures performances en  $Sen$  et en  $TFP$  pour les deux groupes d'apprentissage et de test. Les performances sont légèrement différentes avec, comme attendu, une meilleure classification sur l'ensemble d'apprentissage.

Le système expert basé sur des règles de décision présente une bonne performance sur le groupe d'apprentissage, mais la pire des performances pour le groupe de test. Ceci est un exemple d'un problème de classification classique : le sur-apprentissage (les règles sont adaptées pour le groupe d'apprentissage mais ne peuvent pas être généralisées).

Pour une analyse plus précise des performances individuelles des trois méthodes de classification automatiques, les trois tableaux suivants pour chaque classe de source ont été élaborés (tableaux 3.3, 3.5, 3.4 et 3.6).

**TABLE 3.3.** Identification de l'artéfact oculaire par les trois méthodes de classification sur les deux groupes d'apprentissage et de test

	Distance de Mahalanobis	Classificateur de Bayes	Système expert
	<b>Ensemble d'apprentissage</b>		
<b>Sen<sub>AO</sub></b>	0.9545	1	0.6818
<b>TFP<sub>AO</sub></b>	0.0253	0.0645	0.0023
	<b>Ensemble de test</b>		
<b>Sen<sub>AO</sub></b>	0.8519	0.8889	0.4074
<b>TFP<sub>AO</sub></b>	0.0443	0.0793	0.0070

Le tableau 3.3 présente la performance des trois méthodes de classification pour l'identification des sources d'artéfact oculaire. Dans ce tableau, on constate que le système expert est la méthode la plus conservatrice (la valeur la plus petite pour *TFP*) : cette méthode identifie comme *AO* peu de sources, en diminuant de cette façon les fausses détections des sources cérébrales comme sources d'artéfact.

La classification basée sur la distance de Mahalanobis présente une meilleure performance pour l'identification des sources d'artéfact oculaire (meilleure sensibilité), avec en contre-partie une légère augmentation des fausses détections (*TFP*).

Le classificateur de Bayes (analyse discriminante quadratique) renforce cette tendance : les résultats présentent une augmentation des sources d'artéfact identifiées, mais une augmentation de fausses détections aussi (les valeurs plus hautes de *Sen* et *TFP*).

Ces observations sont valables pour les groupes d'apprentissage et de test, évidemment avec des meilleures performances pour le groupe de test et avec un visible surapprentissage pour la méthode du système expert.

En ce qui concerne l'identification de l'artéfact d'ECG la comparaison entre les trois méthodes automatiques est présentée dans le tableau 3.4. Dans les deux ensembles (d'apprentissage et de test), les trois méthodes présentent une performance excellente avec une bonne valeur de *Sen*, à l'exception surprenante du système expert pour le groupe d'apprentissage. Ce résultat indique par ailleurs que la bonne identification de l'artéfact ECG ne dépend pas uniquement de sa similarité au signal de référence du l'électrocardio-

**TABLE 3.4.** Identification de l'artéfact d'ECG par les trois méthodes de classification sur les deux groupes d'apprentissage et de test

	Distance de Mahalanobis	Classificateur de Bayes	Système expert
<b>Ensemble d'apprentissage</b>			
<b>Sen</b> <sub>AECG</sub>	1	1	0.4286
<b>TFP</b> <sub>AECG</sub>	0	0.0022	0
<b>Ensemble de test</b>			
<b>Sen</b> <sub>AECG</sub>	1	1	1
<b>TFP</b> <sub>AECG</sub>	0	0	0

gramme, mais que les autres caractéristiques (fréquentielles ou spatiales) entrent aussi en jeu.

Le *TFP* est égal à 0 dans tous les cas pour l'identification de l'artéfact d'ECG. Il faut mentionner ici que tous les enregistrements ne présentent pas de source séparée d'artéfact d'ECG (12 sur 38).

**TABLE 3.5.** Identification de l'artéfact de haute fréquence par les trois méthodes de classification sur les deux groupes d'apprentissage et de test

	Distance de Mahalanobis	Classificateur de Bayes	Système expert
<b>Ensemble d'apprentissage</b>			
<b>Sen</b> <sub>AHF</sub>	0.7760	0.8080	0.8320
<b>TFP</b> <sub>AHF</sub>	0.0997	0.1360	0.1360
<b>Ensemble de test</b>			
<b>Sen</b> <sub>AHF</sub>	0.6806	0.7153	0.7014
<b>TFP</b> <sub>AHF</sub>	0.0769	0.1186	0.1378

Le tableau 3.5 compare les trois méthodes de classification pour l'identification des sources d'artéfact de haute fréquence. Les trois méthodes automatiques présentent des résultats similaires de sensibilité.

La méthode de la distance de Mahalanobis présente la valeur la plus petite de *TFP* (moins de fausses détections), cependant la méthode de Bayes et le système expert ont des valeurs de *TFP* assez similaires, avec une meilleure *Sen* pour le classificateur de Bayes.

Les résultats présentés dans ce tableau méritent une discussion plus approfondie. Selon notre opinion, les faibles valeurs de sensibilité et les valeurs élevées du  $TFP$  obtenues pour l'identification de l'artéfact de haute fréquence sont dues à l'ensemble d'apprentissage/ *golden standard*. Pour la construction de l'ensemble d'apprentissage, comme indiqué précédemment, les experts ont choisi uniquement les sources d'artéfact évidentes (pour lesquelles ils étaient sûrs de leur analyse). Les experts ont également indiqué que les sources d'artéfact de haute fréquence sont les plus difficiles à identifier précisément, soit parce qu'elles sont mélangées aux signaux cérébraux, soit parce qu'elles sont similaires à ceux-ci. Par conséquent, une partie des sources d'artéfact de haute fréquence (ou qui contenait des artéfacts haute-fréquence) n'a pas été classée par les experts comme sources d'artéfact, et donc ces sources ont été identifiées par défaut comme sources cérébrales. De ce fait, du point de vue de certaines caractéristiques (fréquentielles principalement) les sources d'artéfact de haute fréquence du *golden standard*/ ensemble d'apprentissage sont proches des sources cérébrales.

Dans ce cas, une valeur faible pour la sensibilité veut dire que seulement peu des sources d'artéfact de haute fréquence ont été identifiées et que les EEGs resteront encore contaminés, cependant il n'y a pas de perte d'information.

Au contraire, une valeur élevée de  $TFP$  veut dire que des sources d'une autre classe (sources cérébrales principalement dans ce cas) ont été classées comme artéfacts de haute fréquence (faux positifs) et par conséquent éliminées dans l'étape suivante. Le résultat, dans ce dernier cas, est une perte d'information qui peut se traduire comme une dégradation des EEGs.

Cependant, la question qui émerge est : les sources classées comme faux positifs  $FP_{AHF}$  sont-elles de vraies sources cérébrales, ou des sources d'artéfact de haute fréquence non identifiées par les experts et donc restantes dans la classe des sources cérébrales ? Seule la validation médicale nous permettra de répondre à cette question : y a-t-il une dégradation en éliminant ces sources (donc étaient-elles vraiment cérébrales) ou une amélioration (auquel cas elles étaient artéfactuelles, mais non détectées par l'expertise médicale des sources) ?

Bien évidemment ce problème est reflété aussi sur les résultats, complémentaires, de la classification de sources informatives cérébrales (classe  $B$ ).

Le tableau 3.6 montre les performances des méthodes de classification pour l'identification des sources cérébrales informatives. Dans ce cas, la méthode de Bayes présente les valeurs les plus faibles pour le  $TFP$  et pour la  $Sen$  : peu de fausses détections, mais de fait il n'y a pas une identification de l'ensemble des sources cérébrales (selon le *golden*

**TABLE 3.6.** Identification des sources cérébrales informatives par les trois méthodes de classification sur les deux groupes d'apprentissage et de test

	Distance de Mahalanobis	Classificateur de Bayes	Système expert
	<b>Ensemble d'apprentissage</b>		
<b>Sen<sub>B</sub></b>	0.8742	0.7815	0.8510
<b>TFP<sub>B</sub></b>	0.1494	0.1039	0.2013
	<b>Ensemble de test</b>		
<b>Sen<sub>B</sub></b>	0.8901	0.8050	0.8404
<b>TFP<sub>B</sub></b>	0.2184	0.1609	0.3333

standard).

A l'opposé, le système expert présente une valeur très haute du *TFP* (beaucoup de fausses détections). L'explication de ce résultat provient de la façon avec laquelle le système expert a été créé : les règles ont été adaptées pour l'identification des artéfacts et spécialement pour faciliter l'identification de l'artéfact oculaire (voire le tableau 3.3, le système expert présente la plus faible valeur de *TFP*).

La méthode de la distance de Mahalanobis identifie correctement plus de sources d'activité cérébrale informative que les autres méthodes (la valeur la plus haute de *Sen*) mais présente aussi une valeur de *TFP* légèrement plus haute que le classificateur de Bayes.

Pour conclure, on peut dire que le système expert montre un sur-apprentissage pour le groupe d'apprentissage et par conséquent la plus faibles des performances.

Pour les deux méthodes d'analyse discriminante (le classificateur de Bayes et la distance de Mahalanobis) le choix est plus difficile. Pour classer les trois types d'artéfacts le classificateur de Bayes a une valeur élevée de *Sen* mais aussi une valeur élevée pour le *TFP*. La méthode détecte bien les sources d'artéfacts, mais plusieurs sources cérébrales sont classées comme sources d'artéfact également (de haute fréquence principalement). Comme discuté précédemment, ce résultat est difficilement interprétable, étant donné la construction du *golden standard*<sup>11</sup>.

Les performances globales (tableau 3.2) sont le reflet de la classification des sources cérébrales informatives. Cela est dû au fait que les sources cérébrales sont plus nombreuses que les sources d'artéfacts, donc une bonne ou une mauvaise classification pour

11. Pour l'identification des sources cérébrales, évidemment la situation est inverse.

la classe  $B$  influence considérablement la classification globale.

En général, on peut conclure que le classificateur de Bayes doit être utilisé uniquement dans l'objectif de préserver les sources cérébrales pour la reconstruction (*i.e.* tous les artefacts doivent être éliminés). Si cette procédure est trop rigoureuse (*i.e.* quand toute l'information doit être préservée), le classificateur basé sur la distance de Mahalanobis pourrait être une meilleure option.

### 3.4.2 Evaluation clinique

Dans cette section, nous présentons les résultats de la deuxième méthode de validation, basée directement sur l'expertise clinique. Quatre versions d'EEGs "propres" ont été comparées : trois proviennent des trois méthodes de classification automatique décrites ci-dessus, et une quatrième version semi-automatique d'EEG reconstruit à partir des sources restantes après l'élimination des sources choisies par les experts cliniques comme artefacts. Le système de notation est celui décrit dans la sous-section 3.3.2.

Selon la validation des experts cliniques, l'amélioration des EEGs propres en comparaison avec l'EEG brut est assez évidente, dans la plupart des cas, quelles que soient les méthodes.

Cependant, certaines nuances peuvent être détaillées, l'élimination des artefacts et la facilité d'interprétation sont très fortement liées : un EEG propre, avec une bonne performance d'élimination des artefacts, permet une meilleure interprétation. Une analyse détaillée est présentée dans les tableaux suivants.

L'EEG reconstruit avec les sources identifiées par le classificateur de Bayes a été noté avec la meilleure performance pour l'élimination de l'artefact oculaire (74 % des EEGs montrent une élimination totale de l'artefact oculaire). La méthode de la distance de Mahalanobis a été classée deuxième, suivie par l'EEG reconstruit à partir des sources choisies par les experts et finalement l'EEG reconstruit par les sources identifiées par le système expert (table 3.7).

Ces résultats confirment les résultats présentés dans le tableau 3.3 : la méthode du classificateur de Bayes a une très haute valeur de  $Sen$  (une très bonne détection de l'artefact oculaire) suivi par la méthode basée sur la distance de Mahalanobis, alors que le système expert montre la pire des performances en raison très certainement du sur-apprentissage.

Comme il a été indiqué par les experts cliniques, l'artefact de haute fréquence a été le plus difficile à identifier et son élimination totale est très difficile. Les résultats ob-



**TABLE 3.7.** Performances de l'élimination de l'artéfact oculaire sur les EEG reconstruits propres (categories : 1 aucun artéfact éliminé, 2 artéfacts éliminés partiellement, 3 aucun artéfact visible)

	Méthodes d'identification			
catégorie	Inspection clinique	Système expert	Distance de Mahalanobis	Classificateur de Bayes
3	42% (16)	26% (10)	50% (19)	74% (28)
2	50% (19)	48% (18)	48% (18)	24% (9)
1	8% (3)	26% (10)	2% (1)	2% (1)

tenus par les quatre méthodes sont très similaires. Toutefois le classificateur de Bayes et la distance de Mahalanobis présentent une meilleure performance que les méthodes d'inspection clinique et du système expert (tableau 3.8). Une fois encore, ces résultats confirment les résultats obtenus pour ce type d'artéfact dans la validation de la classification de sources (tableau 3.5).

**TABLE 3.8.** Performances de l'élimination de l'artéfact de haute fréquence des EEG reconstruits propres (categories : 1 aucun artéfact éliminé, 2 artéfacts éliminés partiellement, 3 aucun artéfact visible)

	Méthodes d'identification			
catégorie	Inspection clinique	Système expert	Distance de Mahalanobis	Classificateur de Bayes
3	13% (5)	13% (5)	21% (8)	21% (8)
2	66% (25)	68% (26)	63% (24)	66% (25)
1	21% (8)	19% (7)	16% (6)	13% (5)

La comparaison des quatre méthodes pour l'identification de l'artéfact d'ECG est présentée dans le tableau 3.9. L'artéfact ECG est complètement éliminé dans les EEG propres reconstruits par le classificateur de Bayes, la méthode de la distance de Mahalanobis et la méthode de l'inspection clinique, alors que le système expert présente une performance moindre. Comme pour les autres artéfacts, ces résultats confirment les résultats du tableau 3.4.

Les résultats des quatre EEGs propres reconstruits selon leur qualité d'interprétation sont présentés dans le tableau 3.10. Ce tableau confirme et nuance les résultats obtenus

**TABLE 3.9.** Performances de l'élimination de l'artéfact d'ECG sur les EEG reconstruits propres (catégories : 1 aucun artéfact éliminé, 2 artéfacts éliminés partiellement, 3 aucun artéfact visible)

	Méthodes d'identification			
catégorie	Inspection clinique	Système expert	Distance de Mahalanobis	Classificateur de Bayes
3	100% (10)	95% (8)	100% (10)	100% (10)
2	0%	0%	0%	0%
1	0%	5% (2)	0%	0%

lors de la validation de la classification de sources.

A partir du tableau 3.10, on peut remarquer que le classificateur de Bayes présente une performance plutôt partagée : cette méthode montre une très bonne amélioration pour 37% des EEGs (le taux le plus haut), mais aussi la valeur de dégradation la plus haute (15%, même si cette dégradation n'est pas très importante, comparée à celle produite par le système expert, qui fournit des EEG notés 1).

**TABLE 3.10.** Résultats de la classification des EEG reconstruits selon leur facilité d'interprétation (catégories : 1 extrêmement pire, 2 pire, 3 égal, 4 mieux, 5 beaucoup mieux)

	Méthodes d'identification			
catégorie	Inspection clinique	Système expert	Distance de Mahalanobis	Classificateur de Bayes
5	32% (12)	13% (5)	24% (9)	37% (14)
4	39% (15)	48% (18)	63% (24)	45% (17)
3	18% (7)	29% (11)	8% (3)	3% (1)
2	11% (4)	8% (3)	5% (2)	15% (6)
1	0%	3% (1)	0%	0%

Une observation intéressante peut être faite pour l'EEG de sommeil : le patient étant endormi aucun artéfact n'est présent dans son EEG. Les 3 méthodes de classification obtiennent le même résultat, correct : aucun artéfact n'est détecté, aucune source éliminée, donc il n'y a pas de perte d'information.

D'une manière globale le classificateur basé sur la distance de Mahalanobis semble avoir la meilleure performance (87% des EEGs sont interprétés plus facilement, tandis

que pour le classificateur de Bayes le score est de 82% ; 71% des EEGs sont améliorés par la méthode visuelle de l'inspection clinique et 61% seulement pour le système expert).

Toutes les méthodes risquent de dégrader l'interprétation de l'EEG. Cependant le risque le plus faible est présenté par la méthode de la distance de Mahalanobis, avec 5% des EEGs dégradés (2 tracés avec une perte de information), tandis qu'ils sont 11% pour l'inspection clinique (2 tracés avec une perte de information et 2 tracés avec des artéfacts restants modifiés), 11% aussi pour le système expert (4 tracés avec des artéfacts restants modifiés) et 15% pour le classificateur de Bayes (4 tracés avec une perte de information et 2 tracés avec des artéfacts restants modifiés).


Les méthodes de l'inspection clinique, la distance de Mahalanobis et le classificateur de Bayes présentent une perte d'information, avec le pourcentage le plus élevé pour le classificateur de Bayes. Le système expert n'engendre pas de perte d'information contrairement à l'inspection clinique et le classificateur de Bayes, cependant les artéfacts qui sont maintenus, risquent de fausser l'interprétation médicale c'est-à-dire conduire à une mauvaise interprétation du tracé.

Un exemple des EEGs reconstruits propres (en montage monopolaire) est montré dans les figures 3.4(a), 3.4(b), 3.5(a), 3.5(b). Comme indique précédemment, dans la section 1.3, les figures concernant l'EEGs réels sont présentées également dans l'annexe A au format A4.

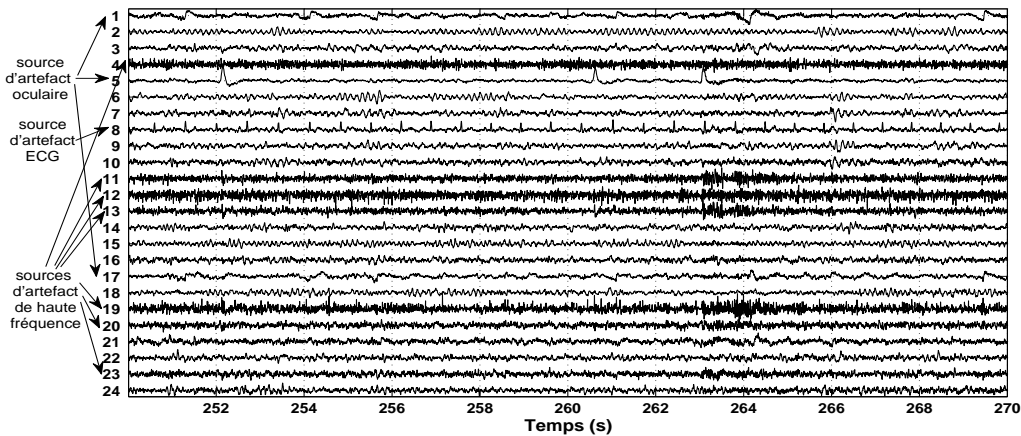
La figure 3.3(a) montre l'EEG brut perturbé par des artéfacts et la figure 3.3(b) illustre les sources estimées après l'application de la SAS (SOBI-RO). Ces sources ont été classées en différents types de sources d'artéfacts et sources informatives par les experts cliniques, comme indiqué dans la figure 3.3(b) : 3 sources d'artéfact oculaire (les sources 1, 5 et 17), 7 sources comme sources d'artéfact de haute fréquence (les sources 4,11,12,13,19,20 et 23) et une source d'artéfact d'ECG (la source 8).

La figure 3.4(b) illustre un EEG propre reconstruit à partir des sources identifiées comme sources informatives par l'inspection clinique (c'est-à-dire après élimination des 11 sources identifiées comme artéfacts). L'amélioration est très claire, même si l'artéfact de haute fréquence n'est pas complètement éliminé. Cet EEG reconstruit a été noté par les experts avec 3 (sur 3) pour l'élimination de l'artéfact oculaire (aucun artéfact présent), 2 (sur 3) pour l'élimination de l'artéfact de haute fréquence (artéfacts partiellement éliminés) et 4 (sur 5) selon leur facilité d'interprétation.

La figure 3.4(a) présente un EEG propre reconstruit à partir des sources identifiées par le système expert. Cette méthode présente une amélioration, mais il y a encore des artéfacts présents : même si l'artéfact de haute fréquence a diminué, l'artéfact oculaire




(a) EEG brut (voir aussi la figure A.1)




(b) sources estimées (voir aussi la figure A.2)

**FIGURE 3.3.** EEG brut et les sources estimées après la SAS. (Sources d'artefact identifiées par les experts cliniques : 1,5,17 (AO), 4,11,12,13,19,20,23 (AHF) , 8 (AECG). Sources d'artefact identifiées par le système expert : 5 (AO), 4,11,12,13,19,20 (AHF). Sources d'artefact identifiées par la méthode de la distance de Mahalanobis 1,5 (AO), 4,12,19 (AHF), 8 (AECG). Sources d'artefact identifiées par le classificateur de Bayes : 1,5,17 (AO), 4,12,19 (AHF), 8 (AECG))




(a) EEG reconstruit avec les sources identifiées par le système expert (voir aussi la figure A.3)




(b) EEG reconstruit avec les sources identifiées par l'inspection clinique (voir aussi la figure A.4)

**FIGURE 3.4.** EEG reconstruits avec les méthodes du système expert et de l'inspection clinique



(a) EEG reconstruit avec les sources identifiées par la méthode de la distance de Mahalanobis (voir aussi la figure A.5)



(b) EEG reconstruit avec les sources identifiées par le classificateur de Bayes (voir aussi la figure A.6)

**FIGURE 3.5.** EEG reconstruits avec les les méthodes de la distance de Mahalanobis et le classificateur de Bayes

reste. Cela est confirmé par le fait que le système expert a identifié une seule source d'artéfact oculaire (la source 5) ; cependant, cette méthode a identifié 6 sources d'artéfact de haute fréquence (les sources 4,11,12,13,19 et 20), mais elle n'a pas identifié la source d'artéfact d'ECG. Les sources non identifiées (AO – 1,17, AHF – 23 et AECG – 8) ont été classées dans la classe B (parmi les sources cérébrales). Cet EEG reconstruit a été noté par les experts avec 2/3 pour l'élimination de l'artéfact oculaire, 2/3 pour l'élimination de l'artéfact de haute fréquence et 3/5 selon la facilité d'interprétation.

Les deux EEG reconstruits par des méthodes de classification supervisée ont une très bonne performance et une quasi totale élimination des artéfacts.

L'EEG propre reconstruit à partir des sources informatives identifiées par la méthode de la distance de Mahalanobis est montré dans la figure 3.5(a). Cette méthode a identifié 2 sources d'artéfact oculaire (les sources 1 et 5), 3 sources d'artéfact de haute fréquence (les sources 4, 12 et 19) et la source d'artéfact d'ECG (la source 8), en tout 6 parmi les 11 sources d'artéfact identifiées par les experts. Les sources non identifiées (AO – 17 et AHF – 11, 13, 20 et 23) ont été classées dans la classe B (parmi les sources cérébrales). Cet EEG reconstruit a été noté par les experts avec 3 pour l'élimination de l'artéfact oculaire, 2 pour l'élimination de l'artéfact de haute fréquence et 4 selon la facilité d'interprétation.

L'EEG propre reconstruit à partir des sources informatives identifiées par le classificateur de Bayes est présenté dans la figure 3.5(b). Cette méthode est la seule méthode automatique qui a identifié les 3 sources d'artéfact oculaire (1, 5 et 17). Elle a aussi identifiée 3 sources d'artéfact de haute fréquence (les sources 4, 12 et 19) et la source d'artéfact d'ECG (la source 8), donc 7 parmi les 11 sources d'artéfact identifiées par les experts. Les sources non identifiées (AHF – 11, 13, 20 et 23) ont été classées dans la classe B (parmi les sources cérébrales). Cet EEG reconstruit a été noté par les experts avec 3 pour l'élimination de l'artéfact oculaire, 2 pour l'élimination de l'artéfact de haute fréquence et 4 selon la facilité d'interprétation.

Remarquablement, dans cet exemple, les trois méthodes automatiques ne font aucune fausse détection, et toutes les mauvaises classifications d'artéfacts placent les sources dans la classe des sources cérébrales (B). Cette situation est générale : toutes les sources d'artéfacts mal classées sont ajoutés à la classe B, ce qui implique que les caractéristiques choisies différencient bien les types d'artéfacts entre eux, mais il y a un risque de confusion avec les sources cérébrales. L'explication peut être double : le *golden standard* est imprécis (au sens où il faudrait construire explicitement une classe d'apprentissage de sources cérébrales, en choisissant selon une procédure similaire à celle utilisée pour les artéfacts), ou alors la séparation est incomplète (au sens où certaines sources estimées res-

tent un mélange de sources d'artéfacts et de sources cérébrales, donc leur classification est ambiguë). Une solution possible, à implémenter en perspective, est une classification moins rigide, qui associe un degré d'appartenance aux classes et/ou qui autorise des points (sources) non-classés (outliers par rapport aux distributions gaussiennes supposées par la règle de Bayes qui est à la base des algorithmes supervisés présentés dans cette thèse).

### 3.5 Conclusion

Le travail présenté dans ce chapitre concerne l'identification de sources d'artéfacts après SAS des EEG de scalp. La méthodologie relève à la fois de l'application de méthodes de SAS et de classification automatique de sources. Toute la difficulté réside dans la validation. Nous avons essayé d'exploiter au maximum l'expertise clinique. En effet un certain nombre de travaux dans ce domaine a été publié ces dernières années. L'originalité de cette partie se situe dans le fait, d'une part, de séparer automatiquement 4 classes ou plus exactement 3 et de considérer la classe 4 (dite sources cérébrales) comme la non appartenance aux trois autres et, d'autre part, dans la validation de la classification à la fois quantitative et qualitative. Si toutefois les deux validations ont pour origine commune l'expertise clinique, elles n'ont pas le même objectif. La première valide le choix des caractéristiques et la méthode de classification alors que la seconde rapporte sur l'intérêt clinique dans le cadre de l'aide au diagnostic et à l'interprétation. A notre sens, cette seconde validation est plus puissante, car elle intègre également l'application des méthodes SAS. Les nombreux résultats présentés montrent de manière générale que ce type de prétraitement apporte un réel bénéfice et doit précéder l'expertise clinique. Évidemment, dans l'objectif de l'intégrer au logiciel d'interprétation en routine clinique, cet outil constituerait un choix possible de prétraitement pour le clinicien au même titre que la possibilité lui est donnée de visualiser le résultat de différents montages pour fournir des informations complémentaires.

Les résultats de ce chapitre présentent également le grand intérêt de devenir le socle de comparaison et de mesures quantitatives objectives de l'opportunité d'adjoindre à ce prétraitement des algorithmes de débruitage. Ce travail fait l'objet du chapitre suivant.





## Chapitre 4

# Débruitage par ondelettes


Les chapitres précédents présentent une méthode d'élimination d'artéfacts pour les signaux EEG de surface, basée sur la séparation de sources et la classification automatique. Cette méthode a été analysée et validée sur des signaux simulés et sur une base de données d'EEG réels, et les résultats obtenus montrent que notre proposition améliore les autres propositions présentées dans la littérature. Néanmoins, quelques problèmes subsistent, notamment dans l'élimination des artéfacts haute-fréquence (musculaires et bruit), qui sont difficilement séparables des sources cérébrales.

L'objectif de ce chapitre est de proposer une solution pour l'amélioration de ce dernier aspect en introduisant une étape supplémentaire, dédiée à l'élimination du bruit, en particulier le débruitage par ondelettes. Nous présentons tout d'abord les méthodes de débruitage par ondelettes puis nous chercherons à répondre aux deux questions suivantes : comment combiner les algorithmes de débruitage avec la séparation et la classification de sources (figure 4.1) de manière à ce que les avantages des trois techniques soient exploités au mieux et non amoindris et quel est l'algorithme de débruitage le plus adapté ?

### 4.1 Débruitage par ondelettes – état de l'art

Comme nous l'avons développé précédemment, le modèle de mélange s'accompagne de sources du bruit additif, modélisées comme stationnaires, avec une origine principalement due aux bruits de mesure. Après séparation, ce bruit est distribué sur les sources (ou, en fonction des algorithmes de séparation, il peut se retrouver d'une manière prépondérante sur un sous-ensemble des sources estimées).

Que ce soit avant ou après séparation (bruit additif sur les électrodes ou bruit additif



**FIGURE 4.1.** *Méthodologie proposée pour l'identification et l'élimination des artefacts et l'élimination du bruit*

sur les sources estimées), il est utile de tenter une réduction de ce bruit afin de faciliter l'interprétation médicale.

Une des méthodes désormais bien établies est le débruitage par ondelettes, qui peut être vu comme un filtrage non linéaire permettant une élimination sélective du bruit additif et une reconstruction du signal débruité très proche du signal d'origine. Ces très bonnes performances s'expliquent par les propriétés de la décomposition en ondelettes, qui ont permis le développement d'un grand nombre de méthodes de débruitage. Une présentation de la décomposition en ondelettes orthogonales et de quelques algorithmes classiques est proposée dans les sous-sections suivantes.

#### 4.1.1 Décomposition en ondelettes

Les ondelettes ont été introduites au début des années 1980, comme une des techniques situées à mi-distance entre la représentation purement temporelle type Dirac et la représentation purement fréquentielle type Fourier.

Les ondelettes sont des outils puissants en analyse mathématique et dans des domaines plus appliqués tels que le traitement du signal et des images, notamment grâce à leurs applications en compression et en débruitage [Coifman et Wickerhauser, 1995; Coifman et Wickerhauser, 1998].

Considérons un signal mesuré discret  $\mathbf{x}$  (un vecteur  $\mathbf{x}(k)$  ( $k = 1 \dots M$ ), avec  $M$  la longueur du signal. Ce signal peut être modélisé comme la somme d'une partie informative  $\mathbf{c}$  et d'un bruit considéré comme un processus aléatoire  $\mathbf{n}$  :

$$\mathbf{x}(k) = \mathbf{c}(k) + \mathbf{n}(k) \quad (4.1)$$

Dans l’application à l’EEG, le signal  $\mathbf{x}$  correspond au signal d’une voie (une électrode de mesure, si on modélise les signaux de surface), ou à une source estimée, si le débruitage est appliqué après séparation. Pour la présentation des méthodes de débruitage, nous allons ignorer cette distinction, le développement étant strictement équivalent. Elle sera re-précisée lors des différentes implémentations possibles (avant/après SAS).

Après une décomposition en ondelettes, le signal  $\mathbf{x}(k)$  ( $k = 1 \dots M$ ) est représenté comme une somme pondérée d’ondelettes à une localisation (temporelle)  $l$  et une échelle (fréquentielle)  $j$  données.

$$\mathbf{x}(k) = \sum_{l=1}^{\frac{M}{2^D}} w_{D,l} \phi_{D,l}(k) + \sum_{j=1}^D \sum_{l=1}^{\frac{M}{2^j}} w_{j,l} \psi_{j,l}(k), \quad (4.2)$$

où  $D$  est la profondeur de la décomposition,  $M$  la longueur du signal,  $j$  ( $j = 1 \dots D$ ) désigne l’échelle (liée à la fréquence),  $l$  indique l’indice de la localisation (liée à la position temporelle),  $w_{j,l}$  est le coefficient de la décomposition à l’échelle  $j$  et la position  $l$ ,  $\phi_{D,l}$  est la fonction d’échelle à la position  $l$  et  $\psi_{j,l}$  est l’ondelette à l’échelle  $j$  et position  $l$ .

Cette représentation implique le calcul des coefficients d’ondelettes  $w_{j,l}$ . Pour une décomposition orthogonale, ces coefficients sont le résultat de la corrélation, au sens du produit scalaire entre le signal à analyser et l’ondelette correspondante localisée en position (temps) et échelle (fréquence).

$$w_{j,l} = \langle \mathbf{x}(k), \psi_{j,l}(k) \rangle = \sum_{k=1}^M \mathbf{x}(k), \psi_{j,l}(k) \quad (4.3)$$

En regroupant tous les coefficients dans un vecteur de longueur égale à  $M$ , la décomposition orthogonale discrète en ondelettes peut aussi s’écrire comme une transformation linéaire<sup>12</sup> :

$$\mathbf{w} = \mathbf{x} \mathbf{T}_{\mathbf{w}}, \quad (4.4)$$

avec  $\mathbf{w}$  le vecteur des coefficients et  $\mathbf{T}_{\mathbf{w}}$  la matrice  $M \times M$  de transformation en ondelettes.

Le vecteur de coefficients  $\mathbf{w}$  a des propriétés différentes en fonction des caractéristiques du signal  $\mathbf{x}$  décomposé.


12. Pour simplifier la notation, nous considérons ici un signal d’une longueur en puissance de 2 et des effets de bord gérés par périodisation. Par conséquent, le nombre de coefficients d’ondelette sera égal au nombre d’échantillons temporels. Cependant, cette simplification n’affecte en rien le développement présenté.

#### 4.1.1.1 Signal informatif

La décomposition en ondelettes d'un signal informatif  $c$  a la propriété d'être parcimonieuse, c'est-à-dire qu'un nombre réduit de coefficients d'ondelettes avec une grande valeur absolue permet de reconstruire (représenter) le signal avec une bonne précision.

La figure 4.2 illustre l'histogramme de la décomposition en ondelettes d'un signal EEG simulé. La distribution du signal est approximativement gaussienne et comprise dans un intervalle  $[-5, 5]$ , alors qu'en analysant la distribution des coefficients d'ondelettes, on voit qu'un grand nombre de coefficients d'ondelettes s'approchent de 0 et seul un petit nombre de coefficients possèdent des valeurs plus élevées (figure 4.2).

La dispersion particulière de la représentation en ondelettes est due au fait que le signal a des composantes localisées à des fréquences et/ou de moments (en temps) précis, ou encore qu'il est corrélé avec l'ondelette choisie, pour certaines échelles (fréquences)  $j$  et localisations temporelles  $l$ .



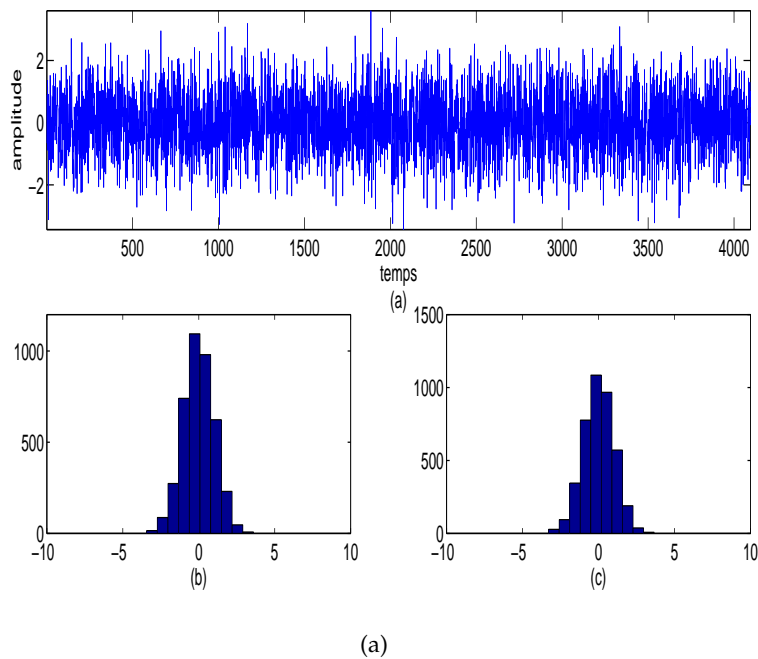
**FIGURE 4.2.** (a) Signal d'EEG simulé (b) Histogramme du signal (c) Histogramme des coefficients d'ondelettes

#### 4.1.1.2 Bruit aléatoire

Le bruit  $n$  est un signal particulier qui, *a priori*, n'est pas corrélé avec une base d'ondelettes (ou encore, il est distribué aléatoirement en temps et en fréquence).

La décomposition en ondelettes du bruit ne génère donc pas des coefficients de très grande valeur absolue. D'une manière plus exacte (voir [Mallat, 1999]), on peut montrer à travers la représentation matricielle de l'équation (4.4), que la distribution des coefficients d'ondelette d'un bruit gaussien reste gaussienne.

La figure 4.3 illustre l'histogramme du bruit et l'histogramme de ses coefficients d'ondelettes, les deux ayant des distributions gaussiennes.



**FIGURE 4.3.** (a) Signal du bruit gaussien (b) Histogramme du bruit (c) Histogramme des coefficients d'ondelettes

#### 4.1.2 Débruitage par seuillage des coefficients d'ondelettes

Le débruitage par seuillage des coefficients d'ondelettes, tel qu'il est défini par [Coifman et Wickerhauser, 1995] revient à "l'extraction d'une structure cohérente" du signal mesuré. Les travaux publiés sont très nombreux et très divers, notamment dans le prétraitement de signaux bio-médicaux (voir [Unser et Aldroubi, 1996] pour un pa-

norama plus détaillé). Des applications ont été développées pour des signaux d'ECG [Li *et al.*, 1995; Cherkassky et Kilts, 2001], des signaux physiologiques abdominaux [Hadjileontiadis *et al.*, 2000; Ranta *et al.*, 2003], des signaux d'EEG [Senhadji *et al.*, 1995; Prasad *et al.*, 2008] et des signaux d'EMG [Khalil *et al.*, 1997a; Khalil *et al.*, 1997b].

Comme les signaux informatifs  $c$  sont localisés en temps et/ou en fréquence (corrélés avec des ondelettes situées à des échelles et localisations précises), les coefficients correspondants issus de la transformation sont de grande amplitude. En revanche, le bruit  $n$  est non corrélé avec les ondelettes et il génère des coefficients de faibles amplitudes. Donc, l'information des signaux est contenue dans les grands coefficients d'ondelettes, alors que les petits coefficients correspondent principalement au bruit. L'idée principale du débruitage par ondelettes est d'appliquer un seuillage, pour séparer les coefficients du bruit de ceux du signal informatif. Tout l'enjeu des méthodes de débruitage par décomposition en ondelettes revient à définir d'une manière optimale le seuil.

#### 4.1.2.1 Algorithme général du débruitage

Le modèle d'un signal bruité le plus utilisé (en notation vectorielle) est donné par l'équation (4.1). Étant donné que la décomposition par ondelettes est linéaire (équation 4.4), l'équation (4.1) est aussi valable pour les coefficients d'ondelettes.

$$\mathbf{w}_x = \mathbf{w}_c + \mathbf{w}_n \quad (4.5)$$

La plupart des coefficients du signal informatif  $\mathbf{w}_c$  sont proches de 0, donc la plupart des coefficients  $\mathbf{w}_x$  sont quasi identiques aux coefficients du bruit. Les coefficients de valeurs absolues élevées, peu nombreux, peuvent être utilisés pour une reconstruction relativement fidèle du signal informatif, en conservant les caractéristiques essentielles en temps et en fréquence (position et échelle).

On peut donc séparer les coefficients  $\mathbf{w}_x$  en deux par seuillage : les coefficients estimés du bruit  $\hat{\mathbf{w}}_n$  et les coefficients estimés du signal informatif  $\hat{\mathbf{w}}_c$ .

L'algorithme général du débruitage par ondelettes est constitué de 3 étapes :

1. Décomposition du signal  $x$  en coefficients d'ondelettes  $\mathbf{w}_x$ .
2. Choix du seuil  $T$  (choix des coefficients de valeurs élevées) pour avoir les coefficients estimés du signal débruité  $\hat{\mathbf{w}}_c$ .
3. Reconstruction à partir des coefficients choisis pour avoir la version du signal  $x$  débruité (estimé)  $\hat{c}$ .

Pour l’implémentation d’une méthode d’élimination du bruit par ondelettes, on doit considérer deux aspects : la stratégie de seuillage et le calcul du seuil.

#### 4.1.2.2 Calcul du seuil

Le problème principal des algorithmes de débruitage par seuillage des coefficients d’ondelettes est de déterminer le seuil : où fixer la frontière entre les petits et les grands coefficients d’ondelettes ? Plusieurs algorithmes ont été proposés ces dernières années ; un panorama très complet des méthodes du calcul de seuil est présenté dans [Antoniadis *et al.*, 2001; Antoniadis *et al.*, 2007].

L’algorithme le plus connu est le seuillage universel (*Uni*) [Donoho et Johnstone, 1994]. Cet algorithme calcule un seuil qui, asymptotiquement, assure l’élimination complète du bruit. En supposant le bruit gaussien normalisé (écart-type unitaire), le seuil  $T$  est défini par :

$$T = \sqrt{2 \log M}$$

où  $M$  le nombre de points du signal.

L’inconvénient principal de cette méthode est la valeur élevée du seuil qui élimine complètement le bruit, mais qui peut conduire à une perte d’information par la déformation du signal.

Une autre approche classique, qui cherche au contraire à préserver au maximum le signal informatif est le seuillage SURE (*Stein Unbiased Risk Estimated*) [Donoho et Johnstone, 1995]. L’idée principale du seuillage SURE est la minimisation de l’erreur quadratique moyenne (EQM) entre le signal débruité estimé  $\hat{\mathbf{w}}_c$  et le signal informatif d’origine  $\mathbf{w}_c$  (respectivement entre leurs coefficients d’ondelettes) :

$$EQM = \|\hat{\mathbf{w}}_c - \mathbf{w}_c\|_2$$

L’algorithme classique proposé par [Donoho et Johnstone, 1995] adapte les seuils à chaque échelle. De plus, il peut être décliné en deux versions :

- R-SURE : dans cet algorithme le seuil est adaptatif aux données, la règle du choix du seuil étant basée sur le calcul d’une estimation non biaisée du risque (EQM) proposé par Stein [Stein, 1981]. Le risque est estimé pour différentes valeur de seuil  $T$  particulières (égales aux coefficients d’ondelettes du signal bruité). On choisit la valeur du seuil qui minimise l’estimation du risque.



- H-SURE est un algorithme heuristique qui résulte d'une combinaison entre le seuillage R-SURE et le seuillage *Uni* : si le signal est "dense", c'est-à-dire ayant un rapport signal/bruit fort, le seuillage R-SURE est utilisé, au contraire si le signal est "rare", c'est-à-dire un rapport signal/bruit faible, c'est le seuillage *Uni* qui est utilisé.

Une troisième méthode de seuillage est le seuillage itératif. Le principe de cette méthode est le suivant : en considérant tous les coefficients d'ondelette, les valeurs significativement élevées (supérieures à une valeur initiale du seuil) sont détectées et séparées. L'algorithme de décomposition et reconstruction est exécuté plusieurs fois, d'une manière itérative, en décomposant à chaque nouvelle itération les "petits" coefficients du bruit reconstruit à l'itération précédente. Les itérations sont interrompues par la validation d'un critère d'arrêt paramétrable par l'utilisateur. La valeur finale du seuil  $T$  obtenu dépend de la paramétrisation de l'algorithme. La méthode est en principe similaire à la recherche itérative d'un estimateur robuste de l'écart-type du bruit  $\sigma_n$  [Ranta *et al.*, 2005].

Cet algorithme a été optimisé par une approche de point-fixe, qui permet de trouver une paramétrisation assurant une conservation maximale du signal (et donc un débruitage minimal), le résultat étant l'algorithme *MinD* [Ranta *et al.*, 2005].

#### 4.1.2.3 Stratégies de seuillage

Dans la littérature, on peut trouver plusieurs méthodes de seuillage, dont les plus connues et appliquées sont le seuillage dur (*hard thresholding*) et le seuillage doux (*soft thresholding*) [Antoniadis *et al.*, 2001; Donoho, 1992; Donoho et Johnstone, 1994].

Le seuillage dur propose l'annulation de toutes les valeurs en dessous d'un seuil  $T$ , les valeurs supérieures restant inchangées :

$$\hat{w}_c = \begin{cases} w_x, & |w_x| \geq T, \\ 0, & |w_x| < T. \end{cases} \quad (4.6)$$

Implicitement, ce type de seuillage considère que les valeurs hautes (correspondant au signal informatif) sont beaucoup plus grandes que les valeurs du bruit, et donc que l'influence du bruit sur ces valeurs est négligeable : elle ne doivent pas être modifiés avant reconstruction.

Le seuillage doux ne fait pas cette dernière hypothèse. Par conséquent, il cherche aussi à éliminer l'influence du bruit sur les grands coefficients. En pratique, il opère, en plus de l'annulation des petits coefficients, une soustraction du seuil  $T$  aux valeurs restantes,

supérieures au seuil. Le résultat permet de réduire le nombre de transitoires de grandes amplitudes dans le signal débruité :

$$\widehat{w}_c = \begin{cases} \text{sign}(w_x) \cdot (|w_x| - T), & |w_x| \geq T, \\ 0, & |w_x| < T. \end{cases} \quad (4.7)$$

En plus du type de seuillage (dur/doux), la stratégie de seuillage peut être adaptée aux caractéristiques énergétiques des signaux traités. En effet, les descriptions précédentes des algorithmes de seuillage considèrent un modèle idéal de bruit (pour *Uni* et *R-SURE*), respectivement du signal plus bruit (*MinD*), dans le sens où la distribution est supposée normalisée quelle que soit l’échelle de la décomposition (écart-type unitaire des coefficients de chaque échelle). Dans le cas général, il est nécessaire d’adapter les seuils  $T$  obtenus précédemment aux caractéristiques des signaux mesurés, et en particulier à la puissance du bruit et à son contenu fréquentiel : les seuils doivent être adaptés localement, par bande de fréquence (échelle de décomposition).

*Seuillage global, bruit blanc.* Pour le seuillage *SURE* et *Uni*, les seuils obtenus (voir sous-section 4.1.2.2) sont multipliés par la puissance du bruit additif  $\sigma_n$ , qui est en principe inconnue et doit être estimée. L’énergie du bruit blanc est répartie sur toutes les échelles de la décomposition. Donc, l’écart-type ( $\sigma_n$ ) est estimé dans une bande où le signal informatif est supposé peu présent, c’est-à-dire, dans la plupart des cas, dans les plus hautes fréquences. Donoho et Johnstone, 1994 proposent un estimateur robuste de  $\sigma_n$  à partir de la valeur médiane  $\theta_{|w^{1,l}|}$  des valeurs absolues des coefficients d’ondelettes de l’échelle haute-fréquence ( $j = 1$ , voir équation 4.3) :

$$\widehat{\sigma}_n = \frac{\theta_{|w^{1,l}|}}{0,6745} \quad (4.8)$$

Pour le seuillage *MinD* tous les coefficients (quelle que soit l’échelle) sont considérés pour le calcul itératif du seuil ;

*Seuillage local, bruit coloré.* Pour le seuillage *SURE* et *Uni*, les seuils sont multipliés par des écarts-types  $\sigma_{n,j}$  estimés de façon individuelle pour chaque échelle  $j$ . La même méthode d’estimation peut être utilisée séparément pour toutes les échelles de la décomposition en ondelettes, ce qui conduit à une estimation de la puissance du bruit par bande de fréquence :

$$\widehat{\sigma}_{n,j} = \frac{\theta_{|w^{j,l}|}}{0,6745} \quad (4.9)$$

Cependant, il faut remarquer que les estimations sont de moins en moins robustes au fur et à mesure que la profondeur augmente, car, d’un côté, le signal est de plus en plus

présent, et de l'autre côté, le nombre de coefficients est de plus en plus faible<sup>13</sup>.

Pour le seuillage *MinD*, des itérations séparées sont réalisées pour chaque échelle  $j$ .

Quelle que soit l'algorithme de calcul du seuil (*Uni*, *SURE*, *MinD*) ou la stratégie de seuillage (dur/doux, global/local) le signal débruité estimé  $\hat{c}$  est obtenu par reconstruction à partir des coefficients d'ondelettes supérieurs au seuil.

Dans le cas d'EEG, il est de grande importance de ne pas perdre d'information potentiellement utile à l'interprétation et au diagnostic médical. D'ailleurs, comme le rapport signal/bruit des EEG est souvent faible, les coefficients d'ondelettes des signaux neuronaux peuvent avoir des valeurs plutôt basses, comparables au bruit. Par conséquent, les algorithmes utilisant un seuil bas tendent à être plus appropriés pour le débruitage (seuillage *SURE* et *MinD*).

Par rapport au contenu fréquentiel du bruit (voir sous-section 2.2.2.2), une première analyse suggère une application préférentielle du seuillage local. Cependant, le signal informatif a un contenu fréquentiel similaire au bruit, et une adaptation des seuils (*i.e.* leur augmentation pour les basses fréquences) risque de provoquer des pertes ou des distorsions d'information. En revanche, un seuil calculé sur la base de la puissance du bruit dans les hautes fréquences (donc comme si le bruit était blanc) est plus faible et élimine moins bien le bruit, tout en préservant mieux le signal informatif.

Selon ce raisonnement, le meilleur choix pour un algorithme de débruitage serait *SURE* ou *MinD*, avec un seuil calculé sur la base d'un bruit blanc de faible puissance (*i.e.* estimée sur l'échelle de haute fréquence). Néanmoins, cette conclusion nécessite une validation expérimentale, à la fois sur des signaux simulés et sur des signaux EEG réels.

## 4.2 Combinaisons de méthodes de traitement : SAS, débruitage et classification

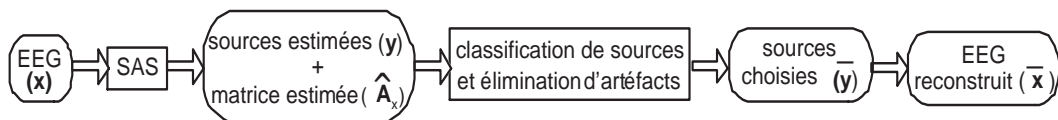
Dans la section précédente, nous avons présenté différentes méthodes de débruitage par ondelettes. Les deux chapitres précédents, quant à eux, présentaient deux autres techniques de traitement de signal, la séparation de sources et la classification, qui ont un objectif complémentaire à l'élimination du bruit, notamment l'élimination des artéfacts extra-cérébraux. La combinaison de ces trois techniques semble donc une bonne solution pour l'élimination simultanée des artéfacts et du bruit et pour la reconstruction d'un EEG

---

13. On rappelle ici que ces estimations ont été utilisées pour estimer le bruit sur les EEG réels dans la sous-section 2.2.2.2

dit "propre", qui pourrait être plus facilement interprétable et/ou analysé automatiquement.

Comme nous l'avons vu dans le chapitre précédent (3), plusieurs applications de combinaisons SAS–classification ont été présentées et appliquées sur les signaux d'EEG [LeVan *et al.*, 2006; James et Gibson, 2003; Greco *et al.*, 2006; Li *et al.*, 2006]. La figure 4.4 rappelle le schéma de traitement et les notations de cette méthodologie.



**FIGURE 4.4.** Chaîne de traitement : SAS et classification

Dans la littérature, on trouve aussi, bien que peu nombreuses, des méthodes de traitement basées sur la combinaison des techniques de SAS et de débruitage par ondelettes. L'étude la plus complète, à notre connaissance, a été présentée par [Rivet *et al.*, 2004], qui analyse, en simulation, différentes combinaisons possibles. Cependant, ces travaux se limitent à la comparaison de deux algorithmes de SAS uniquement (JADE et EASI), pour des rapports signal sur bruit (SNR) très faibles (-10 à 5dB) qui sont en dehors de la plage de simulation adaptée à l'étude des EEG. Nous estimons que les résultats présentés dans ce manuscrit complètent donc les travaux cités. En dehors de cette étude en simulation, la même équipe de recherche propose des applications visant principalement des signaux biologiques comme l'ECG [Vigneron *et al.*, 2003; Rivet *et al.*, 2003]. D'autres applications, sans toutefois une analyse critique des résultats et sans étudier les différentes combinaisons débruitage–séparation possibles, sont proposées sur l'EEG par [Berryman *et al.*, 2004; Rong-Yi et Zhong, 2005; Castellanos et Makarov, 2006].

A notre connaissance, l'application de ces trois techniques combinées (SAS, classification et débruitage), en particulier sur les signaux d'EEG, n'a jamais été étudiée. Cette section explore d'abord les différents schémas de traitement du signal possibles intégrant les trois méthodes décrites ici et vise à choisir la meilleure chaîne de traitement pour l'élimination des artéfacts et du bruit dans les signaux EEG de surface. Nous formalisons d'abord les combinaisons possibles et, par la suite, nous les comparons sur des signaux simulés afin de mettre en évidence, sur des critères objectifs, l'intérêt de l'association et surtout de l'ordonnement des algorithmes. La procédure validée sur des signaux simulés est ensuite appliquée sur des signaux réels.

### 4.2.1 Chaînes de traitement

Avec l'objectif de mieux exploiter les avantages des trois techniques, la combinaison des méthodes de SAS, classification et débruitage peut être implémentée de quatre manières différentes, conduisant à quatre versions d'EEG sans artéfacts débruités :

1. **Débruitage de l'EEG mesuré  $\Rightarrow$  séparation de sources  $\Rightarrow$  classification et élimination  $\Rightarrow$  reconstruction de l'EEG  $\bar{c}_1$ .** Dans cette première implémentation, le débruitage est appliqué sur les signaux des électrodes  $x$ . Cette approche semble être la plus naturelle : avant d'appliquer des techniques de traitement type SAS ou classification, on applique un pré-traitement de type débruitage pour améliorer la qualité des signaux. De cette façon, nous obtenons le mélange débruité  $\hat{c}$ , qui est ensuite séparé par SAS pour obtenir les sources estimées débruitées  $\hat{s}_1$  et la matrice de mélange estimée  $\hat{A}_c$ . Ces sources sont classées et, ensuite, les sources d'artéfacts sont éliminées, pour obtenir un ensemble réduit de sources  $\bar{s}_1$ . Finalement, l'EEG sans artéfacts  $\bar{c}_1$  est reconstruit avec les sources restantes en employant la matrice  $\hat{A}_c$  (fig. 4.5).




FIGURE 4.5. Débruitage de l'EEG brut, avant séparation

2. **Séparation de sources de l'EEG mesuré  $\Rightarrow$  classification et élimination  $\Rightarrow$  reconstruction de l'EEG  $\Rightarrow$  débruitage pour obtenir  $\bar{c}_2$ .** Dans la deuxième implémentation la SAS est appliquée sur les signaux des électrodes  $x$ , comme dans le cas précédent. De cette façon les sources estimées bruitées  $y$  sont obtenues et ensuite classées. Par la suite, les sources classées comme artéfacts sont éliminées pour obtenir l'ensemble réduit  $\bar{y}$  et l'EEG  $x$  est reconstruit avec les sources restantes en utilisant la matrice de mélange estimée  $\hat{A}_x$ . L'étape de débruitage est appliquée à la fin de la chaîne de traitement, sur l'EEG reconstruit  $\bar{x}$ , conduisant ainsi à la version sans artéfacts  $\bar{c}_2$  (figure 4.6).
3. **Séparation de sources de l'EEG mesuré  $\Rightarrow$  classification et élimination  $\Rightarrow$  débruitage  $\Rightarrow$  reconstruction de l'EEG  $\bar{c}_3$ .** Dans la troisième implémentation, la SAS est appliquée au début de la chaîne, directement sur les signaux (bruités) des électrodes  $x$ . Les sources estimées bruitées  $y$  sont ensuite classées et celles classées comme




FIGURE 4.6. Débruitage de l'EEG reconstruit, après la séparation et classification

artéfacts sont éliminées, obtenant l'ensemble réduit  $\bar{y}$ . Après la classification, les sources restantes sont débruitées pour obtenir les sources débruitées  $\bar{s}_3$  et l'EEG  $\bar{c}_3$  est reconstruit en utilisant la matrice de mélange estimée  $\hat{A}_x$  (fig. 4.7).




FIGURE 4.7. Débruitage des sources estimées, après séparation et classification

4. **Séparation de sources de l'EEG mesuré  $\Rightarrow$  débruitage des sources  $\Rightarrow$  classification et élimination  $\Rightarrow$  reconstruction de l'EEG  $\bar{c}_4$ .** Dans cette dernière implémentation, la SAS est placée au début de la chaîne pour obtenir  $y$ , comme dans les deux cas précédents. Les sources estimées bruitées  $y$  sont ensuite débruitées pour obtenir les estimations  $\hat{s}_4$ . Ces estimations sont classées, les sources identifiées comme artéfacts sont éliminées pour obtenir l'ensemble réduit  $\bar{s}_4$  qui est utilisé pour reconstruire (à l'aide de la matrice de mélange estimée  $\hat{A}_x$ ) l'EEG  $\bar{c}_4$  (figure 4.8).




FIGURE 4.8. Débruitage des sources estimées, après séparation et avant classification

Parmi ces trois grandes étapes (SAS, débruitage, classification), le débruitage par ondelettes tient un rôle particulier. En fait, le débruitage est une étape de traitement qui conduit à une perte de signal et donc potentiellement à une élimination d'une partie de l'information, susceptible d'être utile à la fois à la séparation de sources et à la classification. Certes, un débruitage parfait élimine uniquement le bruit et ne change pas l'information présente dans les signaux, mais le risque pris en l'appliquant avant les deux autres étapes est relativement grand dans les cas pratiques.

Par exemple, dans la quatrième chaîne présentée ci-dessus (**SAS** → **débruitage** → **classification**), le débruitage est appliqué sur les sources obtenues après séparation, et ce sont les sources débruitées qui sont classées. Nous avons écarté cette implémentation dans l'application sur l'EEG réel<sup>14</sup>. L'heuristique de cette démarche est la suivante : la meilleure façon de reconnaître les sources d'artéfacts est de faire la classification le plus tôt possible dans la chaîne, afin de modifier le moins possible les signaux soumis à l'expertise médicale (car, comme toute classification supervisée, elle est basée sur un apprentissage). En particulier, le bruit haute fréquence qui peut être présent sur les signaux issus des électrodes risque d'être modifié partiellement par le débruitage et d'être confondu avec les artéfacts musculaires, qui sont eux aussi caractérisés par des fréquences plus hautes que l'activité cérébrale : une source cérébrale encore bruitée pourrait donc être identifiée comme un artéfact. Dans l'autre sens, par débruitage, un artéfact musculaire risque d'être modifié de telle manière qu'il serait non reconnu par l'expert et donc par l'algorithme de classification, et donc il pourrait être classé comme source cérébrale. Selon ce raisonnement, la quatrième chaîne de traitement (pour obtenir  $\bar{c}_4$ ) peut être écartée.

#### 4.2.2 Ordonnement : débruitage et séparation

En analysant les trois chaînes de traitement restantes (conduisant à  $\bar{c}_1$ ,  $\bar{c}_2$  et  $\bar{c}_3$ ), le débruitage par ondelettes est placé après la séparation de sources dans les deux derniers cas, donc il n'influence pas l'estimation du mélange. En revanche, dans le premier cas, il modifie les résultats de la SAS. Cette modification est attendue : elle peut être bénéfique (par l'élimination du bruit) ou, au contraire, elle peut provoquer des pertes d'information et conduire à une mauvaise séparation. Compte tenu des résultats présentés dans le chapitre 2, le niveau de bruit influence les performances de la SAS (l'indice de séparabilité). Tous les algorithmes se comportent mieux sur des signaux non bruités et, qui plus est, leur performances changent : si, sur les signaux bruités, SOBI-RO est le plus performant pour les EEG simulés, quand le bruit est nul, le meilleur algorithme est MULTICOMBI. Autrement dit, un débruitage performant nous conduirait à choisir ce dernier algorithme à la place de SOBI-RO.

Pour analyser les relations entre SAS et débruitage, reprenons le modèle du mélange instantané de l'éq. (2.1) :

$$\mathbf{X} = \mathbf{A}\mathbf{S} + \mathbf{N} \quad (4.10)$$

avec  $\mathbf{A}$  la matrice de mélange  $Q \times P$  et  $\mathbf{X}$ ,  $\mathbf{S}$  et  $\mathbf{N}$  les matrices  $M$  colonnes (correspondant

---

14. sous supervision médicale

à  $M$  échantillons temporels) regroupant respectivement les  $Q$  mesures, les  $P$  sources et les  $Q$  bruits. La décomposition en ondelettes étant une transformation linéaire, l'équation (4.10) se transforme, par multiplication à droite par la matrice de transformation en ondelettes  $T_w$  en :

$$\mathbf{W}_x = \mathbf{A}\mathbf{W}_s + \mathbf{W}_n, \quad (4.11)$$

les matrices  $\mathbf{W}_x$ ,  $\mathbf{W}_s$  et  $\mathbf{W}_n$  étant les matrices des coefficients d'ondelettes des signaux mesurés, des sources et des bruits additifs respectivement.

Soit  $\mathbf{x}_i = [x_i(1), x_i(2), \dots, x_i(M)]$  le signal  $i$  de  $M$  échantillons. Le vecteur des coefficients d'ondelettes de ce signal<sup>15</sup>  $\mathbf{w}_{x,i}$  s'écrit :

$$\begin{aligned} \mathbf{w}_{x,i} &= [w_{x,i}(1), w_{x,i}(2), \dots, w_{x,i}(M)] = \mathbf{a}_i \begin{bmatrix} \mathbf{w}_{s,1} \\ \mathbf{w}_{s,2} \\ \vdots \\ \mathbf{w}_{s,P} \end{bmatrix} + \mathbf{w}_{n,i} \\ \mathbf{w}_{x,i} &= [a_{i,1}, a_{i,2}, \dots, a_{i,P}] \begin{bmatrix} w_{s,1}(1) & w_{s,1}(2) & \dots & w_{s,1}(M) \\ w_{s,2}(1) & w_{s,2}(2) & \dots & w_{s,2}(M) \\ \vdots & \vdots & \ddots & \vdots \\ w_{s,P}(1) & w_{s,P}(2) & \dots & w_{s,P}(M) \end{bmatrix} + [w_{n,i}(1), \dots, w_{n,i}(M)] \end{aligned} \quad (4.12)$$

avec  $\mathbf{a}_i$  la ligne  $i$  de la matrice de mélange,  $\mathbf{w}_{s,p}$  les coefficients d'ondelettes de la source  $p$  et  $\mathbf{w}_{n,i}$  les coefficients d'ondelettes du bruit additif sur le capteur  $i$ .

Le débruitage par ondelettes d'un signal  $\mathbf{x}_i$  implique la transformation de son vecteur de coefficients d'ondelettes  $\mathbf{w}_{x,i}$  en fonction d'un seuil<sup>16</sup>  $T$ . Les équations de débruitage présentées au début de ce chapitre (section 4.1) peuvent s'écrire sous une forme matricielle comme une multiplication du vecteur des coefficients par une matrice diagonale de seuillage  $\mathbf{F}_{T,x_i}$ . Le vecteur des coefficients d'ondelettes du signal débruité  $\widehat{\mathbf{c}}_i$  sera :

$$\widehat{\mathbf{w}}_{c,i} = \mathbf{w}_{x,i} \mathbf{F}_{T,x_i} = \mathbf{w}_{x,i} \begin{bmatrix} f(w_{x,i}(1)) & 0 & 0 & \dots & 0 \\ 0 & f(w_{x,i}(2)) & 0 & \dots & 0 \\ 0 & 0 & f(w_{x,i}(3)) & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & f(w_{x,i}(M)) \end{bmatrix} \quad (4.13)$$

15. Comme indiqué au début de ce chapitre (section 4.1), nous avons choisi une décomposition en ondelettes telle que le nombre de coefficients d'ondelettes sera égal au nombre d'échantillons temporels.

16. ou de plusieurs seuils  $T_j$  différents par échelle; cependant, le développement présenté ici reste le même.



avec

$$f(w_x) = \begin{cases} 1, & |w_x| \geq T, \\ 0, & |w_x| < T. \end{cases}$$

pour un seuillage dur (*hard*) et

$$f(w_x) = \begin{cases} \text{sign}(w_x) \left[ \frac{|w_x| - T}{w_x} \right], & |w_x| \geq T, \\ 0, & |w_x| < T. \end{cases}$$

pour un seuillage doux (*soft*).

Sans débruitage, le traitement appliqué aux EEG bruts ( $x_i$ ) consiste en SAS (qui fournit une matrice de mélange estimée  $\hat{A}_x$  et des sources estimées  $y_i$ ). Par reconstruction, après l'élimination éventuelle des sources d'artéfacts (étape de classification), on obtient  $\bar{x}_i$  (identiques à  $x_i$  si aucune source d'artéfacts n'est identifiée).

Comme indiqué précédemment, l'introduction du débruitage dans la chaîne de traitement peut donc être faite à trois endroits différents :

1. Avant la séparation, sur les signaux bruts  $x_i$ . La matrice de seuillage appliquée pour obtenir  $\hat{c}_i$  est dans ce cas  $F_{T,x_i}$ . En remplaçant (4.12) dans (4.13), on obtient :

$$\mathbf{w}_{\hat{c}_i} = \mathbf{w}_{x_i} \mathbf{F}_{T,x_i} = \mathbf{a}_i \begin{bmatrix} \mathbf{w}_{s,1} \\ \mathbf{w}_{s,2} \\ \vdots \\ \mathbf{w}_{s,P} \end{bmatrix} \mathbf{F}_{T,x_i} + \mathbf{w}_{n,i} \mathbf{F}_{T,x_i} \quad (4.14)$$

Autrement dit, le seuillage du vecteur des coefficients d'ondelettes du signal  $x_i$  est équivalent à un seuillage, avec le même algorithme de seuillage (même matrice diagonale  $F_{T,x_i}$ ), de chacun des vecteurs des coefficients d'ondelettes des sources qui le composent.

2. Après séparation (matrice  $\hat{A}_x$ ) et classification, sur les sources estimées restantes  $\bar{y}$ . Le résultat du débruitage est alors le vecteur des sources  $\bar{s}_2$ , obtenu en appliquant les matrices de seuillage  $F_{T,\bar{y}_p}$  :

$$\mathbf{w}_{\bar{s}_2,p} = \mathbf{w}_{\bar{y},p} \mathbf{F}_{T,\bar{y}_p} \quad (4.15)$$

L'équation du mélange débruité (4.14) est réécrite comme :

$$\widehat{\mathbf{w}}_{\bar{c}_2,i} = \widehat{\mathbf{a}}_{x,i} \begin{bmatrix} \widehat{\mathbf{w}}_{\bar{y},1} \\ \widehat{\mathbf{w}}_{\bar{y},2} \\ \vdots \\ \widehat{\mathbf{w}}_{\bar{y},P} \end{bmatrix} \quad (4.16)$$

Remplacer (4.15) dans (4.16) met en évidence que le signal reconstruit débruité dans ce deuxième cas (SAS avant débruitage) dépend de plusieurs matrices de seuillage  $\mathbf{F}_{T,\bar{y}_p}$ , adaptées à chacune des sources estimées.

3. Après reconstruction, sur le mélange reconstruit  $\bar{x}$  à partir des sources identifiées comme informatives ( $\bar{y}$ ) et de la matrice de mélange estimée sur les mesures  $\hat{\mathbf{A}}_x$ . Dans ce dernier cas, la matrice de seuillage pour le signal  $\bar{x}_i$  sera  $\mathbf{F}_{T,\bar{x}_i}$ , adaptée aux signaux mélangés mais sans artéfacts :

$$\mathbf{w}_{\bar{c}_3,i} = \mathbf{w}_{\bar{x},i} \mathbf{F}_{T,\bar{x}_i} \quad (4.17)$$

Dans le premier cas (4.14), on peut observer que les sources individuelles qui se mélangent pour former le signal mesuré risquent d'être déformées par un seuillage qui n'est pas adapté à leurs caractéristiques, mais à celles du mélange. Une modification des sources intervenant dans le mélange se reflète directement dans la séparation : elle est appliquée sur les coefficients débruités  $\mathbf{w}_{\hat{c}}$  (ou, d'une manière équivalente, sur les signaux débruités  $\hat{c}$ ). La matrice de mélange estimée sera  $\hat{\mathbf{A}}_c$  et l'évaluation de la qualité de séparation à travers l'indice de séparabilité (2.27) impliquera une matrice de transfert  $G = \hat{\mathbf{A}}_c^{-1} \mathbf{A}$  (2.26), qui risque d'être relativement éloignée d'une matrice diagonale permutée selon le raisonnement précédent.

Un éclairage supplémentaire pourrait être celui de la projection sur un repère orthogonal obtenue après l'élimination de certains vecteurs de la base d'ondelettes : en effet, le débruitage par ondelettes par seuillage est équivalent à une reconstruction partielle, éventuellement pondérée pour le seuillage doux, donc à une reconstruction qui emploie un sous-ensemble des vecteurs de base (ondelettes). Le choix de ces vecteurs est crucial pour un débruitage correct or, conformément à l'équation (4.14), le choix est fait en fonction des caractéristiques du mélange et non pas en fonction des caractéristiques individuelles des sources. Par exemple, on pourrait avoir une source  $s_p$  qui participe peu au mélange à cause d'un coefficient  $a_{i,p}$  faible. Après seuillage, cette source risque d'être complètement perdue, et appliquer un algorithme de séparation de sources sur un mélange débruité risque de conduire à des mauvais résultats en terme d'estimation du mélange et donc des sources sous-jacentes.

Enfin, comme par hypothèse les sources sont indépendantes, leurs coefficients d'ondelettes le seront aussi. De plus, un vecteur de coefficients d'ondelettes d'un signal est en général creux, on peut raisonnablement supposer que l'indépendance des deux vecteurs de coefficients se reflète dans une distribution dans le plan temps-fréquence (temps-échelle) relativement disjointe (autrement dit, les sources ont des caractéristiques temps

fréquence différentes). Cet argument, même sans preuve formelle, met en lumière le risque d'un seuillage commun sur les différentes sources : la matrice de seuillage  $\mathbf{F}_{T,x_i}$  va extraire la même information temps-fréquence de toutes les sources  $s_p$  et du bruit  $\mathbf{n}_i$ , donc va diminuer l'indépendance. De plus, si les sources ont des décompositions creuses et disjointes, la décomposition en ondelettes d'un signal mélangé est plus riche, ce qui implique que, pour un rapport signal sur bruit donné, les coefficients informatifs sont moins facilement séparables par seuillage des coefficients du bruit. Autrement dit, les matrices de seuillage  $\mathbf{F}_{T,x_i}$  sont plus difficiles à estimer que les matrices de seuillage des sources  $\mathbf{F}_{T,\bar{y}_p}$ .

Selon la discussion précédente, la deuxième solution (4.15) n'interfère pas avec la séparation et ne risque pas de compromettre ses performances. Autrement dit, si le débruitage des mélanges n'est pas extrêmement performant (*i.e.* si toute l'information n'est pas préservée), il est plus sûr de résoudre le problème du bruit affectant les mesures par des solutions alternatives au débruitage, à travers notamment les algorithmes de séparation robustes au bruit décrits dans le chapitre 2.

Dans le troisième cas (4.17), nous revenons sur un débruitage plutôt adapté au mélange (sans artéfacts néanmoins) qu'aux sources individuelles, comme dans (4.14)<sup>17</sup>. Cependant, les mélanges sans artéfacts sont *a priori* moins riches que les mélanges artéfactés, et donc le débruitage devrait être plus facile. Il est vrai que débruiter le mélange reconstruit conduit à l'élimination des mêmes caractéristiques temps-fréquence (ondelettes) sur toutes les sources, mais ces ondelettes contribuent peu au signal mesuré sans artéfacts. Si certaines caractéristiques temps-fréquences des sources se perdent, cette perte est peu significative pour les signaux mesurés, autrement dit elle affecte peu l'interprétation de l'EEG de surface.

Il est utile de préciser ici qu'une autre implémentation combinée séparation-débruitage a été proposée par [Rivet *et al.*, 2004]. Dans l'approche présentée, deux étapes de débruitage sont incluses dans la chaîne, une précédant la séparation, pour estimer la matrice de mélange, et une autre après séparation, pour débruiter les sources. Cependant, du point de vue de la séparation de sources, cette implémentation est équivalente à la première chaîne proposée : la matrice de séparation est obtenue à partir des signaux débruités, et donc elle risque d'être perturbée par la perte (distortion) de l'information due au débruitage.

---

17. Mais la possible déformation des sources à travers le seuillage du mélange n'affecte plus la SAS.

#### 4.2.2.1 Simulation

Une première simulation vise donc à évaluer l'influence du débruitage sur la séparation de sources : selon la discussion précédente, un débruitage très performant pourrait améliorer les performances des algorithmes de séparation et changer leur classement, établi dans le chapitre 2. Cependant, selon cette même discussion, le débruitage, dans la mesure où il déforme les signaux, risque d'éliminer des informations et nuire à la séparation de sources. L'objectif de ces premières simulations est donc de trancher entre ces deux hypothèses.

**Algorithmes de débruitage.** En utilisant les quatre méthodes de seuillage présentées dans la section précédente (R-SURE, H-SURE, *Uni* et *MinD*) et avec les différents stratégies de seuillage, nous avons testé 16 versions d'algorithmes de débruitage : chacun des algorithmes avec des stratégies global-dur, global-doux, local-dur et local-doux.

Plusieurs familles d'ondelettes ont été testées, mais les résultats sont similaires. Les valeurs présentées dans cette thèse ont été obtenues avec des Symlets 7 (*sym7*). En ce qui concerne la profondeur de la décomposition en ondelettes, nous avons choisi  $D=6$  ( $j=1 \dots 7$  échelles de décomposition), étant donné que la fréquence d'échantillonnage est de 256 Hz. Une décomposition de profondeur  $D=6$  implique que la dernière échelle (l'approximation) est en dessous de 1 Hz, c'est-à-dire la fréquence informative la plus basse (bandes physiologiques).

**Algorithmes de séparation.** Selon le chapitre 2, les meilleures performances pour les EEG bruités sont obtenues par l'algorithme SOBI-RO (basé sur les statistiques d'ordre deux). En revanche, sur des signaux sans bruit, l'algorithme combiné MULTICOMBI est plus efficace. Nous avons donc comparé ces deux algorithmes en combinaison avec les 16 algorithmes de débruitage.

**Résultats.** Afin de trouver la combinaison la plus performante, les  $16 \times 2$  méthodes ont été testées sur l'EEG simulé d'activité normale bruité (mille matrices de mélange). Nous avons utilisé, comme pour la séparation seule, 4 rapports signal/bruit (5dB, 10dB, 15dB, 20dB), avec du bruit blanc et coloré (voir aussi section 2.2.2.2). Le critère de performance utilisé pour cette comparaison est l'indice de séparabilité  $IS$  : effectivement, l'objectif est de déterminer si le débruitage améliore ou non la séparation de sources.

Les tableaux 4.1 (SOBI-RO) et 4.2 (MULTICOMBI) présentent les  $IS$  obtenus sur l'EEG brut simulé avec du bruit blanc. Les résultats correspondants pour le bruit coloré sont

**TABLE 4.1.** Performances de séparation par SOBI-RO pour les EEG simulés (bruit blanc, 4 SNR). IS moyen sur EEG brut (SD) et pour les 16 versions débruitées

SNR	SD	R-SURE	H-SURE	Uni	minD	R-SURE	H-SURE	Uni	minD
		global dur				global doux			
<b>IS</b>									
5dB	<b>0.1288</b>	0.1488	0.1605	0.1896	0.1822	0.1569	0.1614	0.1924	0.1826
10dB	<b>0.0998</b>	0.1250	0.1297	0.1566	0.1566	0.1303	0.1310	0.1648	0.1647
15dB	<b>0.0753</b>	0.1011	0.1096	0.1274	0.1344	0.1074	0.1088	0.1449	0.1509
20dB	<b>0.0571</b>	0.0757	0.0850	0.1071	0.1198	0.0867	0.0873	0.1289	0.1422
		local dur				local doux			
<b>IS</b>									
5dB	<b>0.1288</b>	0.2209	0.2224	0.2254	0.2125	0.2159	0.2233	0.2217	0.2263
10dB	<b>0.0998</b>	0.1915	0.2179	0.2166	0.2078	0.1946	0.2163	0.2122	0.2193
15dB	<b>0.0753</b>	0.1796	0.2200	0.2142	0.2064	0.1846	0.2143	0.2053	0.2186
20dB	<b>0.0571</b>	0.1772	0.2219	0.2133	0.2056	0.1820	0.2157	0.2024	0.2185

**TABLE 4.2.** Performances de séparation par MULTICOMBI pour les EEG simulés (bruit blanc, 4 SNR). IS moyen sur EEG brut (SD) et pour les 16 versions débruitées

SNR	SD	R-SURE	H-SURE	Uni	minD	R-SURE	H-SURE	Uni	minD
		global dur				global doux			
<b>IS</b>									
5dB	<b>0.1994</b>	0.2450	0.2768	0.3182	0.2692	0.2361	0.2771	0.2707	0.2492
10dB	<b>0.1719</b>	0.1791	0.1870	0.2301	0.2252	0.1762	0.2083	0.2362	0.2384
15dB	0.1516	0.1497	0.2563	0.1600	0.1881	<b>0.1441</b>	0.1733	0.1949	0.2130
20dB	0.1272	0.1262	0.2577	0.1256	0.1626	<b>0.1179</b>	0.1331	0.1724	0.1974
		local dur				local doux			
<b>IS</b>									
5dB	<b>0.1994</b>	0.3182	0.3091	0.2894	0.2239	0.2927	0.2687	0.2577	0.2182
10dB	<b>0.1719</b>	0.2423	0.2727	0.2577	0.2136	0.2484	0.2407	0.2231	0.2078
15dB	0.1516	0.2106	0.2563	0.2274	0.2093	0.2183	0.2439	0.2054	0.1964
20dB	0.1272	0.1982	0.2577	0.2170	0.2054	0.2066	0.2485	0.1973	0.1891

4.2. Combinaisons de méthodes de traitement : SAS, débruitage et classification

**TABLE 4.3.** Performances de séparation par SOBI-RO pour les EEG simulés (bruit coloré, 4 SNR). IS moyen sur EEG brut (SD) et pour les 16 versions débruitées

SNR	SD	R-SURE	H-SURE	Uni	minD	R-SURE	H-SURE	Uni	minD
		global dur				global doux			
<b>IS</b>									
5dB	<b>0.1813</b>	0.1848	0.1853	0.1892	0.1966	0.1821	0.1821	0.1837	0.1906
10dB	<b>0.1488</b>	0.1503	0.151	0.1548	0.1648	0.1494	0.1495	0.1603	0.1716
15dB	<b>0.1234</b>	0.1242	0.1249	0.1301	0.1417	0.1244	0.1245	0.1402	0.1553
20dB	<b>0.1008</b>	0.1009	0.1013	0.1108	0.1245	0.1018	0.1017	0.1247	0.1437
		local dur				local doux			
<b>IS</b>									
5dB	<b>0.1813</b>	0.2367	0.2270	0.2385	0.2185	0.2253	0.2375	0.2424	0.2441
10dB	<b>0.1488</b>	0.2081	0.2188	0.2224	0.2093	0.2077	0.2237	0.2288	0.2330
15dB	<b>0.1234</b>	0.182	0.2180	0.2168	0.2057	0.189	0.2238	0.2229	0.2269
20dB	<b>0.1008</b>	0.1732	0.2201	0.2141	0.2023	0.1835	0.2215	0.2196	0.2242

**TABLE 4.4.** Performances de séparation par MULTICOMBI pour les EEG simulés (bruit coloré, 4 SNR). IS moyen sur EEG brut (SD) et pour les 16 versions débruitées

SNR	SD	R-SURE	H-SURE	Uni	minD	R-SURE	H-SURE	Uni	minD
		global dur				global doux			
<b>IS</b>									
5dB	<b>0.2013</b>	0.2270	0.2548	0.2677	0.3125	0.2227	0.2384	0.2727	0.2959
10dB	<b>0.1641</b>	0.1699	0.1871	0.1921	0.2333	0.1724	0.1966	0.2165	0.2533
15dB	0.1397	0.1418	0.1513	0.1526	0.1983	<b>0.1396</b>	0.1606	0.1861	0.2178
20dB	0.1164	0.118	0.1209	0.1297	0.1628	<b>0.1139</b>	0.1253	0.1629	0.2040
		local dur				local doux			
<b>IS</b>									
5dB	<b>0.2013</b>	0.3350	0.3332	0.3086	0.2332	0.2270	0.2548	0.2715	0.2273
10dB	<b>0.1641</b>	0.2647	0.2832	0.2691	0.2177	0.1699	0.1871	0.2339	0.2169
15dB	0.1397	0.2118	0.2569	0.2372	0.2098	0.1418	0.1513	0.2163	0.2049
20dB	0.1164	0.1932	0.2504	0.2168	0.2102	0.1180	0.1209	0.2058	0.1950

présentés dans les tableaux 4.3 (SOBI-RO) et 4.4 (MULTICOMBI). A partir de ces résultats, on peut conclure :

- l’introduction de l’étape de débruitage (algorithme R-SURE) améliore légèrement les résultats obtenus par l’algorithme MULTICOMBI sans débruitage ;
- les résultats obtenus avec l’algorithme SOBI-RO sans débruitage restent supérieurs à ceux obtenus avec l’algorithme MULTICOMBI avec débruitage. Donc, l’algorithme SOBI-RO sera utilisé dans la méthodologie appliquée sur les signaux réels ;
- l’introduction de l’étape de débruitage avant la séparation de sources détériore l’ $IS$  obtenu sans débruitage par SOBI-RO. Cela confirme l’analyse présentée ci-dessus (section 4.2.1) et peut s’expliquer par le fait que le débruitage risque de supprimer une partie du signal et/ou de modifier la structure du mélange, et en conséquence gêner la qualité de l’estimation de la matrice de séparation. Nos résultats étendent ceux présentés par [Rivet *et al.*, 2004], qui montre que, pour certains algorithmes de séparation, le débruitage pré-séparation améliore les performances ( $IS$ ). Cependant, dans l’article cité, cette amélioration est significative pour les bruit très forts (SNR négatifs) et elle devient très faible pour un SNR de 5dB, qui est la valeur maximale considérée. De plus, les auteurs n’incluent pas dans leur comparaison des algorithmes de séparation avec un blanchiment robuste, et donc mieux adaptés aux situations simulées.

Nous proposons donc d’appliquer l’étape de débruitage après la séparation, afin de préserver les performances de séparation et, éventuellement, d’améliorer de cette façon les performances globales sur l’estimation des sources. La première chaîne de traitement, conduisant aux signaux estimés  $\bar{c}_1$  est donc écartée. Cette conclusion nous amène à nous interroger sur les deux autres implémentations de chaîne de traitement restantes : le débruitage sur le mélange reconstruit  $\bar{c}_2$  et le débruitage sur les sources estimées suivi de la reconstruction ( $\bar{c}_3$ ). Nous rappelons ici que le mélange reconstruit débruité  $\bar{c}_2$  est identique à  $\hat{c}$  (débruitage sur les signaux d’origine) si la classification et l’élimination des artéfacts ne sont pas incluses dans la chaîne).

### 4.2.3 Ordonnancement : débruitage et reconstruction

En plus de l’ordonnancement, les simulations précédentes nous ont permis de choisir aussi l’algorithme de séparation de sources le plus adapté pour notre application (sous réserve du réalisme de la simulation, bien entendu) : il s’agit de l’algorithme basé sur des statistiques d’ordre deux et le blanchiment robuste SOBI-RO. Reste à choisir l’algorithme

de débruitage, ainsi que son emplacement exact dans la chaîne de traitement : action sur les sources estimées ou sur le mélange reconstruit.

Selon le développement précédent, pour un rapport signal sur bruit donné, il semblerait plus logique de débruiter les sources que le mélange : les signaux sont plus creux et leur débruitage est plus facile. Cependant, même si débruiter le mélange reconstruit conduit à l'élimination des mêmes caractéristiques temps-fréquence (ondelettes) sur *toutes* les sources, ces ondelettes contribuent peu au signal mesuré, car leurs coefficients sont de faible amplitude. Cette perte est donc peu significative pour les signaux mesurés, autrement dit, elle affecte peu l'interprétation de l'EEG de surface. De plus, on peut aussi argumenter que, si l'objectif est de faciliter l'interprétation des signaux de surface (mélangés), alors il est plus logique d'appliquer un débruitage qui leur est dédié. Nous avons donc décidé de simuler les deux situations et d'évaluer les performances du débruitage à la fois sur les sources et sur le mélange. Les 16 versions des algorithmes de débruitage ont été testées sur l'EEG brut (avec du bruit blanc et coloré) et sur les sources bruitées (avec du bruit blanc et coloré). Pour éviter de prendre en compte les erreurs d'estimation dues à l'algorithme de séparation, nous avons considéré directement les sources d'origine (autrement dit, nous avons simulé une implémentation du débruitage après une séparation parfaite).

Cependant, même une séparation parfaite n'est pas capable d'estimer l'amplitude des sources. Il est par exemple impossible de faire la différence entre une source faible mais "proche" des électrodes (générateur de faible amplitude, mais propagation importante) et une source forte mais éloignée (générateur fort mais fortement atténué). En fait, les algorithmes de séparation attribuent une variance unitaire à toutes les sources estimées, ce qui implique qu'ils ajustent (à travers un gain) les lignes correspondantes de la matrice de séparation  $B$ . Cet ajustement a une conséquence directe sur la séparation des mélanges bruités : même si le rapport signal sur bruit est le même pour toutes les électrodes, après séparation, le bruit est réparti différemment sur les sources estimées (et ceci même si la séparation est parfaite, au sens où les sources sont parfaitement retrouvées, à l'exception de leur amplitude et leur ordre). Autrement dit, pour simuler correctement le débruitage des sources, il n'est pas suffisant d'ajouter aux sources simulées un bruit avec les SNR mesurés sur les EEG réels, comme dans les simulations précédentes, car le vrai bruit réparti sur les sources peut avoir une puissance complètement différente, dépendant à la fois des caractéristiques des sources et du mélange.

Ce raisonnement conduit à une première conclusion sur les algorithmes de débruitage :



- il est très probable qu'un même algorithme de débruitage soit le plus adapté pour les **signaux mélangés**, dans la mesure où leur SNR est similaire. De plus, si l'objectif est de préserver un maximum d'information (application EEG), un seuillage de type R-SURE devrait être plus approprié ;
- en revanche, pour les **sources estimées**, il est très possible que l'algorithme le plus adapté soit différent d'une source à une autre, en fonction du SNR, et que le seuillage *Universal* soit le plus performant (on rappelle ici qu'en principe les sources sont plus faciles à débruiter, car leur coefficients d'ondelettes sont plus grands devant le bruit). En pratique néanmoins, le SNR sur les sources est impossible à connaître, car ni leur amplitude d'origine ni le mélange ne sont connus

Quatre situations sont désormais possibles :

1. Débruitage **fort** (*Universal*) sur le **mélange reconstruit** : comme dans le premier cas, l'élimination du bruit est prioritaire. En plus, conformément au raisonnement précédent, le débruitage des signaux mélangés est plus difficile que celui des sources. Par conséquent, il est fort probable que le mélange  $\bar{c}_2$  perde une partie de l'information.
2. Débruitage **faible** (R-SURE, *MinD*) sur le **mélange reconstruit** : cette solution provoquera théoriquement un minimum de perte d'information sur le signal mélangé reconstruit  $\bar{c}_2$ , car le seuillage est directement adapté à ses caractéristiques.
3. Débruitage **fort** (*Universal*) sur les **sources estimées** : cette approche considère l'élimination du bruit comme prioritaire. Le risque, si le SNR est faible, est de déformer fortement les sources concernées, avec en conséquence une perte d'information importante dans le mélange  $\bar{c}_3$ .
4. Débruitage **faible** (R-SURE, *MinD*) sur les **sources estimées** : en considérant la reconstruction du signal prioritaire, les sources ont plus de chances d'être préservées (même si le bruit reste présent). Cette solution est théoriquement celle qui assure la meilleure reconstruction des sources d'origine et donc aussi un résultat  $\bar{c}_3$  probablement correct.

Par conséquent, il semblerait que, si l'on veut préserver l'information, il est préférable d'effectuer un débruitage R-SURE (voire *MinD*) soit sur les sources soit sur le mélange.

#### 4.2.3.1 Simulation

Nous présentons ici les résultats des simulations effectuées pour valider l'analyse précédente. Les mêmes 16 versions d'algorithmes de débruitage ont été utilisées, sur les

sources et sur le mélange.

**Performances des algorithmes de débruitage.** Pour l'évaluation des algorithmes de débruitage, nous avons employé le critère du rapport signal/bruit ( $SNRx$ ) entre les signaux originaux  $c$  et leur versions débruitées  $\bar{c}$  ( $\bar{c}_2$  et  $\bar{c}_3$ , en fonction de la chaîne de traitement). Ce critère, appliqué pour la composante  $c_i$  du mélange ( $i = 1 \dots Q$ ), s'écrit :

$$SNRx_i = 10 \log_{10} \frac{\sum_{k=1}^M c_i(k)^2}{\sum_{k=1}^M (c_i(k) - \bar{c}_i(k))^2} \quad (4.18)$$

où  $M$  est le nombre d'échantillons du signal et  $\bar{c}_i$  est sa version débruitée.

Pour prendre en compte l'efficacité du débruitage sur les  $Q$  voies, les valeurs obtenues ont été moyennées pour obtenir  $SNRx$ .

**Résultats : mélange reconstruit.** Les premières simulations concernent le mélange reconstruit (identique à celui d'origine en absence de classification). Les résultats obtenus avec les différentes distributions de bruit sont similaires. Par conséquent, nous présentons ici les valeurs moyennées pour les trois types de bruit.

Dans un premier temps, le bruit a été considéré blanc. Le tableau 4.5 présente les résultats obtenus par les 16 versions des algorithmes de débruitage, sur l'EEG simulé, en prenant comme critère la valeur de  $SNRx$  (4.18) entre les signaux mélangés non bruités ( $c$ ) et les signaux débruités ( $\bar{c}$ ). Dans un deuxième temps, pour se rapprocher plus des situations réelles telles qu'analysées précédemment, le bruit a été considéré coloré (avec un contenu fréquentiel similaire à celui estimé à partir des EEG réels, voir sous-section 2.2.2.2). Les résultats pour le bruit coloré sont présentés dans le tableau 4.6

Un exemple d'EEG d'activité normale simulée, sans bruit, est présenté à la figure 4.9(a). La figure 4.9(b) présente sa version bruitée (bruit blanc,  $SNR = 10\text{dB}$ ). Des exemples de résultats du débruitage sont présentés aux figures 4.9(c) pour R-SURE et 4.9(d) pour le seuillage universel, tous étant implémentés avec une stratégie de seuillage doux global.

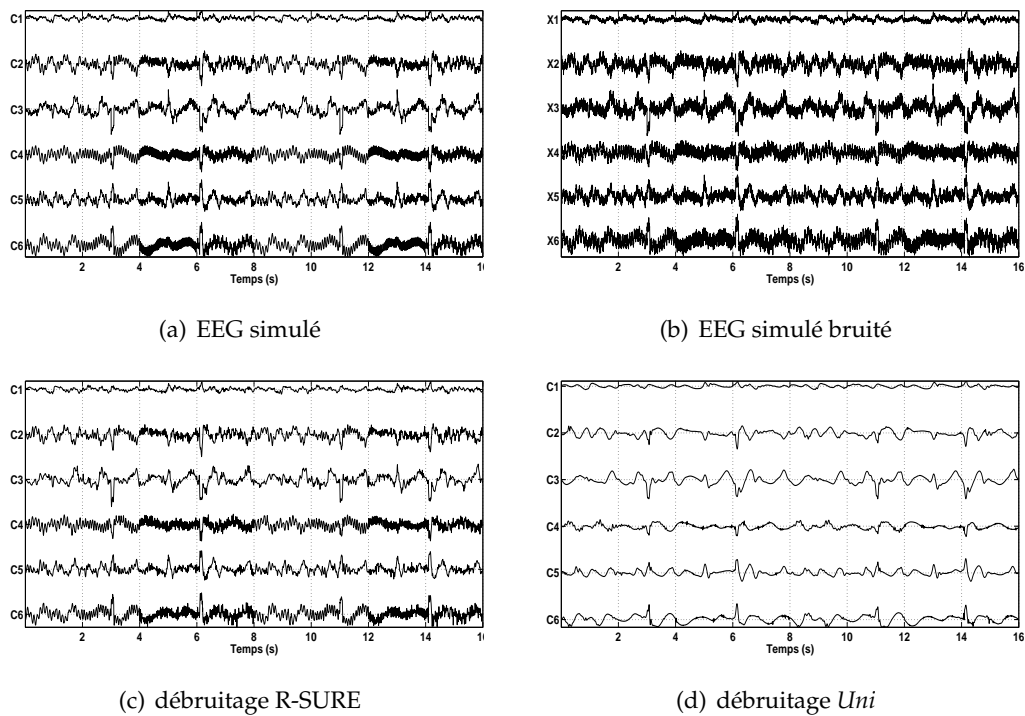
En général, les résultats montrent que, dans le cas du bruit coloré, les performances de tous les algorithmes sont moins bonnes que pour le bruit blanc (valeurs de  $SNRx$  plus petites). Il est cependant relativement clair que, quel que soit l'algorithme, les résultats obtenus avec une stratégie de seuillage global sont plus performants. L'explication est

**TABLE 4.5.**  $SNR_x$  pour  $\bar{c}_2$  (reconstruction suivie de débruitage). Le mélange d'origine a été bruité avec du bruit blanc

SNR	R-SURE	H-SURE	Uni	minD	R-SURE	H-SURE	Uni	minD
	global dur				global doux			
	<b>SNR<sub>x</sub></b>							
5dB	8.8616	10.2731	7.2007	1.3024	<b>11.0046</b>	10.7162	5.5293	1.2949
10dB	12.6869	14.0295	10.7281	2.7916	<b>14.5380</b>	14.0462	7.7329	2.7845
15dB	16.7545	17.2975	14.2662	3.401	<b>18.0452</b>	17.6577	10.4296	3.3958
20dB	20.8605	20.862	17.141	3.6146	<b>21.4055</b>	21.0740	12.9989	3.6106
	local dur				local doux			
	<b>SNR<sub>x</sub></b>							
5dB	5.9133	4.3344	3.6457	4.9605	5.609	3.7583	3.1313	4.9604
10dB	7.8771	4.8444	3.9069	9.8272	6.7049	4.1482	3.2971	9.7992
15dB	8.9614	5.3191	4.0271	14.4253	7.2897	4.5245	3.3983	14.3212
20dB	9.5645	5.7012	4.0763	18.8275	7.5927	4.8824	3.4443	18.7575

**TABLE 4.6.**  $SNR_x$  pour  $\bar{c}_2$  (reconstruction suivie de débruitage). Le mélange d'origine a été bruité avec du bruit coloré

SNR	R-SURE	H-SURE	Uni	minD	R-SURE	H-SURE	Uni	minD
	global dur				global doux			
	<b>SNR<sub>x</sub></b>							
5dB	5.6976	5.8274	7.0669	1.3502	6.7374	6.7137	<b>7.1740</b>	1.3553
10dB	10.5746	10.7165	11.1033	2.8266	<b>11.4275</b>	11.368	9.776	2.8311
15dB	15.3466	15.3601	14.7765	3.4317	<b>15.9348</b>	15.8168	12.419	6.3434
20dB	19.9311	19.7149	17.9175	3.6453	<b>20.0753</b>	19.8900	14.6705	3.6452
	local dur				local doux			
	<b>SNR<sub>x</sub></b>							
5dB	5.0247	3.9373	3.4120	4.9714	4.9072	3.4145	2.9202	4.9587
10dB	7.1417	4.5214	3.769	9.8313	6.0819	3.8775	3.1589	9.8280
15dB	8.7517	4.9484	3.9564	14.4323	6.9426	4.2763	3.2981	14.3700
20dB	9.6022	5.4632	4.0456	18.7646	7.3953	4.6944	3.3701	18.6879




**FIGURE 4.9.** Exemple de débruitage sur un EEG simulé (bruit blanc,  $SNR=10dB$ )

donnée par le contenu fréquentiel du bruit simulé : pour un même rapport signal sur bruit, la puissance du bruit dans les basses fréquences (là où le signal informatif est présent aussi) est plus importante, et donc son élimination plus difficile. Ceci nous amène à conclure que, pour les EEG réels, où il est impératif de ne pas perdre de l'information potentiellement utile au diagnostic médical, une stratégie de seuillage global est plus adaptée. La figure 4.10 permet une comparaison entre le seuillage global et le seuillage local (R-SURE) pour un tracé d'EEG réel.


En conséquence, sur le mélange reconstruit, deux constats peuvent être mis en évidence :

- les algorithmes avec une stratégie globale sont plus performants (sauf *MinD*) ;
- l'algorithme R-SURE (avec un stratégie de seuillage doux global) présente les meilleures performances quels que soient la distribution du bruit et le  $SNR$  (seule exception, le bruit coloré très fort,  $SNR$  5dB).

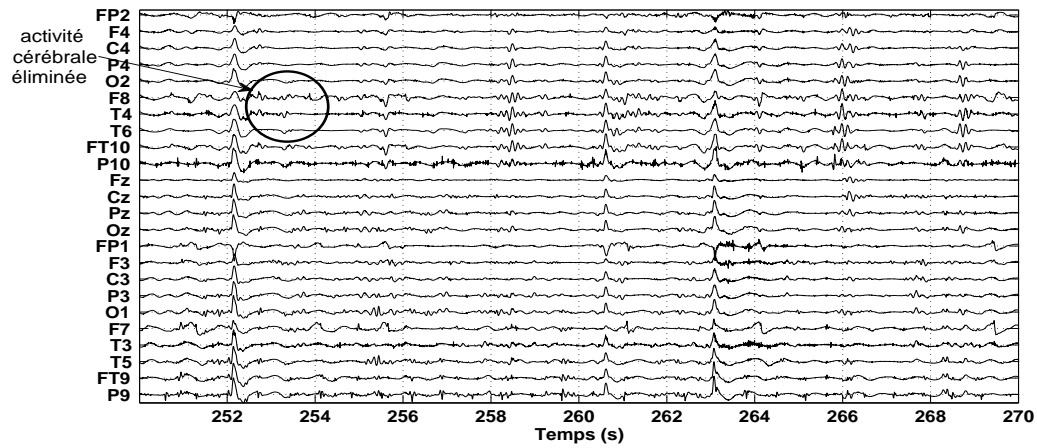
**Résultats : sources estimées.** La simulation est plus problématique pour les sources estimées car, comme nous l'avons mentionné précédemment, la puissance du bruit qui les



(a) EEG réel (voir aussi la figure A.7)



(b) Débruitage global (voir aussi la figure A.8)



(c) Débruitage local (voir aussi la figure A.9)

**FIGURE 4.10.** Exemple de débruitage local et global sur un EEG réel

perturbe dépend de la matrice de séparation estimée, qui elle-même contient une indétermination fondamentale (amplitude des sources versus gain de la ligne correspondante) : les sources qui participent faiblement au mélange (soit parce qu'elles sont de faible amplitude, soit parce que les coefficients du mélange sont petits) auront des estimations plus bruitées que les autres. Dans le cas idéal, on devrait choisir l'algorithme de débruitage en fonction du  $SNR$  pour chacune des sources estimées, mais comme celui-ci est inconnu, nous avons considéré le même algorithme de débruitage pour toutes les sources et nous avons calculé la moyenne  $SNRx$ . Les résultats présentés ici sont donc à prendre avec précaution : la moyenne peut être issue des performances très différentes d'une source à une autre.

Les résultats obtenus sur l'EEG reconstruit après le débruitage de sources sont montrés dans les tableaux 4.7 (pour le bruit blanc) et 4.8 (pour le bruit coloré).

**TABLE 4.7.**  $SNRx$  pour  $\bar{c}_3$  (débruitage suivi de reconstruction). Le mélange d'origine a été bruité avec du bruit blanc

SNR	R-SURE	H-SURE	Uni	minD	R-SURE	H-SURE	Uni	minD
	global dur				global doux			
	<b>SNRx</b>							
5dB	7.6966	9.5205	7.2956	1.2948	<b>10.5044</b>	9.6072	5.5417	1.3021
10dB	11.0205	12.3392	9.849	2.7845	<b>13.3772</b>	12.4207	7.2701	2.7914
15dB	14.1212	14.762	12.1103	3.3958	<b>16.0134</b>	15.012	9.1205	3.401
20dB	17.0561	17.1224	13.9851	3.6106	18.4107	17.4687	10.9158	3.6146
	local dur				local doux			
	<b>SNRx</b>							
5dB	5.6974	4.6682	4.2872	4.9963	6.3074	4.4612	3.7733	4.9859
10dB	8.1373	5.4821	4.7324	9.9615	7.6366	5.2105	4.1638	9.8749
15dB	9.7279	6.173	5.0508	14.8212	8.5322	5.8384	4.4663	14.473
20dB	10.8600	6.5705	5.3829	<b>19.1617</b>	9.1104	6.2397	4.7192	18.9988

On constate que l'algorithme R-SURE (avec une stratégie de seuillage doux global) est le plus performant pour l'élimination du bruit blanc (sauf pour 20dB) et également pour le bruit coloré (sauf pour un bruit très fort 5dB).

Les tableaux précédents permettent de comparer les résultats obtenus sur le mélange reconstruit débruité et sur le mélange reconstruit à partir de sources débruitées. Dans

**TABLE 4.8.**  $SNR_x$  pour  $\bar{e}_3$  (débruitage suivi de reconstruction). Le mélange d'origine a été bruité avec du bruit coloré

SNR	R-SURE	H-SURE	Uni	minD	R-SURE	H-SURE	Uni	minD
	global dur				global doux			
	<b>SNR<sub>x</sub></b>							
5dB	5.7148	5.838	7.5852	1.3555	6.9412	6.9236	<b>8.0727</b>	1.35
10dB	10.5635	10.7063	11.0664	2.8311	<b>11.6644</b>	11.6147	10.3213	2.8265
15dB	15.2743	15.344	14.0689	3.4341	<b>16.1623</b>	16.0298	12.4417	3.4317
20dB	19.7077	19.5274	16.6109	3.6452	<b>20.2120</b>	19.888	14.3301	3.6453
	local dur				local doux			
	<b>SNR<sub>x</sub></b>							
5dB	5.7685	4.2872	3.7819	5.0201	5.0201	3.8409	3.2336	5.0216
10dB	8.4104	5.0330	4.3565	9.9832	9.9832	4.6512	3.6973	9.962
15dB	10.2434	5.9326	4.7813	14.8453	14.8453	5.6951	4.195	14.7375
20dB	11.371	6.6207	5.2177	19.2889	19.2889	6.4436	4.5737	18.6896

le cas appliqué du bruit blanc, les performances sont légèrement meilleures quand le débruitage est sur les mélanges reconstruits débruités (tableau 4.5, à comparer avec le tableau 4.7). En revanche, dans le cas du bruit coloré, les meilleures performances sont obtenues sur le mélange reconstruit avec les sources débruitées (tableau 4.8 versus tableau 4.6). Toutefois, dans les deux cas, les résultats sont très similaires. Enfin, dans la quasi totalité des implémentations, l'algorithme de débruitage R-SURE (avec une stratégie de seuillage doux global) semble le plus adapté à notre application.

En analysant les résultats des différentes chaînes de traitement étudiées, on peut conclure :

- dans le cas d'un EEG sans artéfacts, si aucune source n'est susceptible d'être éliminée et si l'objectif est uniquement l'amélioration de l'interprétation médicale, l'application du débruitage seul semble suffisante (voir tableau 4.5);
- si au contraire l'EEG est artéfacté et/ou si on veut connaître les sources cérébrales ou extra-cérébrales pour des étapes ultérieures, la séparation de sources doit être faite avant l'étape de débruitage.

Reste à choisir la place du débruitage sur un enregistrement réel, en général contaminé par artéfacts : sur les sources estimées ou sur l'EEG reconstruit après élimination

des sources d'artéfacts ? La comparaison entre les résultats finaux (mélanges reconstruits  $\bar{c}_2$  et  $\bar{c}_3$ ) ne permet pas de trancher clairement.

Dans un souci de rigueur médicale et afin d'éviter d'abîmer les signaux, nous avons appliqué les deux méthodes sur plusieurs EEG réels et nous les avons soumis à la validation des experts médicaux. Néanmoins, après analyse, les experts ont indiqué qu'il n'y a pas de différences visibles entre les deux versions d'EEGs débruités. Étant donné que l'objectif de cette thèse est de proposer une méthodologie de pré-traitement pour faciliter l'interprétation visuelle et automatique des EEG de surface, la deuxième implémentation sera appliqué aux signaux d'EEG réels (figure 4.7) c'est-à-dire le débruitage sera appliqué sur l'EEG reconstruit après l'élimination des artéfacts.

La figure 4.11(a) montre un exemple d'EEG reconstruit avec débruitage sur les sources (avant reconstruction) et la figure 4.11(b) montre un exemple d'EEG reconstruit débruité (après reconstruction).


### 4.3 Débruitage des EEG réels

Dans la section précédente, nous avons conclu que si l'objectif est de faciliter l'interprétation médicale, le débruitage devra être fait sur l'EEG reconstruit après séparation et élimination des artéfacts.


Les EEGs sans artéfacts obtenus après reconstruction à partir des sources informatives ont donc été débruités en utilisant le seuillage SURE, le plus performant selon les simulations précédentes (voir aussi [Vigneron *et al.*, 2003] pour des résultats similaires).

Pour la validation médicale de l'étape de débruitage (et donc de la chaîne complète) nous avons utilisé les EEGs reconstruits en utilisant une des deux méthodes de classification les plus performantes : la distance de Mahalanobis.





(a) EEG reconstruit avec débruitage des sources (avant reconstruction) (voir aussi la figure A.10)



(b) EEG reconstruit débruité (après reconstruction) (voir aussi la figure A.11)

**FIGURE 4.11.** EEG reconstruit débruité

### 4.3.1 Validation

L'intérêt du débruitage est d'éliminer le bruit des EEGs, présent principalement en hautes fréquences où il n'y a pas ou presque pas d'information, et donc il porte aussi sur l'amélioration de la facilité d'interprétation.

Par conséquent, les experts cliniques ont comparé l'EEG brut ( $\mathbf{x}$ ) avec l'EEG reconstruit sans artéfacts  $\bar{\mathbf{x}}_2$  (avant débruitage) et avec l'EEG sans artéfacts débruité  $\bar{\mathbf{c}}_2$  et ils ont évalué l'élimination du bruit et l'amélioration de la facilité d'interprétation.

Comme pour l'élimination d'artéfacts seule, les experts ont classé les EEG sans artéfacts et débruités dans 5 catégories selon leur facilité d'interprétation par rapport aux EEGs d'origine : **1** extrêmement pire, **2** pire, **3** égal, **4** mieux, **5** beaucoup mieux. Les EEGs ont aussi été classés en 3 catégories selon l'élimination du bruit : **1** non élimination du bruit, **2** bruit éliminé partiellement, **3** pas de bruit visible.

### 4.3.2 Résultats

Dans le tableau 4.9 sont présentés les résultats de cette validation. En les analysant on voit que le débruitage améliore considérablement l'élimination des hautes fréquences non informatives. En comparant le tableau 4.9 avec le tableau 3.8 (élimination de l'artéfact de haute fréquence) le pourcentage des EEGs reconstruits avec une élimination totale des hautes fréquences (notés avec 3) passe de 21% à 63%. En considérant une amélioration globale (notés avec 2 et 3) le pourcentage passe de 84% à 98%.

**TABLE 4.9.** Performances de l'élimination du bruit sur les EEGs reconstruits propres débruités (catégories : **1** non élimination du bruit, **2** bruit éliminé partiellement, **3** pas de bruit visible)

	Méthodes d'identification et de débruitage
catégorie	Distance de Mahalanobis débruitage (seuillage SURE)
<b>3</b>	63% (24)
<b>2</b>	35% (13)
<b>1</b>	2% (1)

Quant à la facilité d'interprétation, les résultats sont présentés dans le tableau 4.10. En comparant ces résultats avec le tableau 3.10 (amélioration de la facilité d'interprétation après l'élimination d'artéfacts uniquement) on voit que le pourcentage des EEGs nettement améliorés (notés avec 5) augmente de 24% à 48% et de façon globale les EEGs plus

faciles à interpréter (notés avec 4 et 5) augmentent de 87% à 96%.

**TABLE 4.10.** Performances du débruitage sur les EEGs reconstruits propres débruités selon leur facilité d'interprétation (catégories : 1 extrêmement pire, 2 pire, 3 égal, 4 mieux, 5 beaucoup mieux)

	Méthodes d'identification et de débruitage
catégorie	Distance de Mahalanobis débruitage (seuillage SURE)
5	48% (18)
4	48% (18)
3	2% (1)
2	2% (1)
1	0% (0)


Enfin, les tableaux 4.9 et 4.10 nous permettent de mettre en évidence que, si le pourcentage d'EEGs améliorés augmente, celui des EEGs détériorés n'augmente pas (donc on ne perd pas d'information avec le débruitage).

La figure 4.12(a) présente une exemple d'EEG sans artéfacts et la figure 4.12(b) sa version sans artéfacts débruitée .


## 4.4 Conclusion

Les résultats du débruitage sont relativement difficiles à interpréter, surtout au vu des exemples sur les signaux réels (voir figure 4.10) : il semblerait qu'un certain degré de débruitage est utile, mais il faut être très prudent pour ne pas perdre de l'information et déformer les signaux informatifs. La conclusion des simulations et des analyses visuelles sur les signaux simulés est que les EEG bruts peuvent être améliorés sans perte d'information en appliquant un algorithme réputé pour fournir des seuils de faible valeurs (et donc une élimination partielle du bruit) comme R-SURE, avec un seuillage doux. De plus, il est plus prudent d'éventuellement sous-estimer la puissance du bruit, en considérant que son niveau, quelle que soit la bande de fréquence, est égal au niveau de la bande la moins énergétique (en occurrence, pour les EEG, les fréquences les plus hautes).

Cependant le choix d'un algorithme de débruitage avec un seuil faible n'est pas suffisant, si l'on veut associer le débruitage à d'autres techniques comme la SAS. Une mauvaise combinaison risque de déformer les signaux d'EEG : par exemple, le débruitage des



(a) EEG reconstruit avec les sources identifiées par la méthode de la distance de Mahalanobis (voir aussi la figure A.12)



(b) EEG reconstruit avec les sources identifiées par la méthode de la distance de Mahalanobis débruité (voir aussi la figure A.13)

**FIGURE 4.12.** EEG reconstruit sans artéfacts et EEG reconstruit sans artéfacts débruité

signaux d'EEG avant d'appliquer la SAS et la classification peut conduire à une mauvaise estimation des sources et du mélange, ainsi qu'à une classification plus difficile.

En revanche, un algorithme de débruitage adapté aux signaux d'EEG (*i.e.* R-SURE), appliqué après la séparation et la classification de sources (soit sur le mélange reconstruit, soit sur les sources estimées) semble une solution performante pour l'élimination des artéfacts et du bruit et donc pour l'amélioration de l'interprétation des signaux d'EEG, tout en préservant l'information sur l'activité cérébrale.



## Chapitre 5

# Application clinique : EEG épileptiques

Ce dernier chapitre a pour objectif de mettre en évidence l'intérêt de la méthodologie de prétraitement développée et validée précédemment à travers deux applications particulièrement intéressantes du point de vue clinique. La première application concerne l'interprétation des signaux d'EEG réels pathologiques et plus particulièrement les signaux enregistrés au cours d'épilepsies du lobe temporel. La seconde partie montre, sur quelques exemples, l'intérêt que peut apporter le prétraitement dans des procédures de type étude de relations intersignaux (inter électrodes) dans le cadre de la caractérisation de la crise d'épilepsie.

### 5.1 Séparation, classification et débruitage des EEGs critiques

Cette première partie porte sur l'intérêt de l'élimination d'artéfacts et du bruit sur des EEGs pathologiques afin d'améliorer leur interprétation et en conséquence le diagnostic clinique. Dans un premier temps, la méthodologie de pré-traitement appliquée est strictement la même que celle présentée dans les chapitres précédents, sur les EEG inter-critiques.

#### 5.1.1 Base de données

Cinquante et un EEG de surface incluant une crise, enregistrés sur 28 patients épileptiques adultes (23 patients avec 2 enregistrements et 5 patients avec 1 seul enregistre-

ment), âgés entre 16 et 56 ans, diagnostiqués avec épilepsies temporales, ont été acquis avec un système Micromed à l'hôpital CHU-Nancy. Ces EEGs ont été enregistrés pour chaque patient en utilisant 24 électrodes placées sur le cuir chevelu selon le système international 10-20 avec une référence commune placée proche des yeux, à l'électrode FPz. Les signaux enregistrés ont été échantillonnés à 256 Hz et un filtre coupe-bande a été appliqué à 50 Hz. Un des EEGs a la particularité d'être enregistré en phase précritique/critique au cours du sommeil ; il n'est donc pas contaminé par des artéfacts de surface.

## 5.1.2 Méthodologie de traitement et analyse

### 5.1.2.1 Séparation de sources

Une fenêtre de 20 secondes de chaque enregistrement a été utilisée pour la séparation de sources : cette fenêtre contient 10 secondes d'activité pré-critique (supposée normale) et 10 secondes d'activité critique pathologique : le début de la crise est donc placé au milieu de la fenêtre. Il est à préciser que les départs de crise sont renseignés par le ou les cliniciens.

### 5.1.2.2 Classification des sources estimées

L'identification et la classification des sources d'artéfacts ont été développées en utilisant deux méthodes automatiques de classification supervisée : la distance de Mahalanobis et le classificateur de Bayes (le système expert a été écarté, étant donné les performances qu'il présente sur les EEG inter-critiques – voir chapitre 3). L'ensemble d'apprentissage utilisé pour l'élimination d'artéfacts sur des EEGs critiques a été construit avec les caractéristiques des sources d'artéfacts identifiées par les experts cliniques dans les EEGs inter-critiques (38 enregistrements). Autrement dit, l'ensemble d'apprentissage pour le cas critique est plus riche que celui utilisé dans le cas inter-critique du chapitre 3, car il inclut aussi l'ensemble de test utilisé dans la sous-section 3.4.

### 5.1.2.3 Débruitage

L'étape de débruitage a été implémentée selon le développement présenté dans le chapitre 4, c'est-à-dire par un algorithme R-SURE (stratégie de seuillage local doux) sur les EEGs reconstruits après l'élimination des sources d'artéfacts par les 3 méthodes de classification (une visuelle – l'inspection clinique, et deux automatiques – la distance de Mahalanobis et le classificateur de Bayes).

#### 5.1.2.4 Validation médicale

Après l'application du débruitage, 3 EEGs reconstruits sans artéfacts et débruités ont été obtenus. Ces 3 EEGs reconstruits automatiquement, l'EEG sans artéfacts reconstruit après l'inspection clinique des sources séparées (sans débruitage – identification visuelle des artéfacts) et l'EEG brut ont été comparés par les experts afin d'évaluer 2 aspects :

- l'amélioration de l'interprétation physiologique, dans ce cas la détection et l'interprétation d'une crise épileptique ;
- l'élimination d'artéfacts.

Les experts ont comparé les 5 EEGs différents (l'EEG brut, 3 EEGs sans artéfacts débruités, l'EEG sans artéfacts reconstruit par l'inspection clinique) et ils les ont classés de la même manière que dans le cas des EEGs inter-critiques :

- dans 5 catégories selon leur facilité d'interprétation : **1** extrêmement pire, **2** pire, **3** égal, **4** mieux, **5** beaucoup mieux et
- en 3 catégories selon l'élimination des artéfacts : **1** aucun artéfact éliminé, **2** artéfacts éliminés partiellement, **3** aucun artéfact visible.

La validation médicale a été faite en aveugle, c'est-à-dire sans aucune connaissance de la méthode utilisée pour l'élimination des artéfacts.

#### 5.1.3 Résultats

Dans cette section, nous présentons successivement les résultats obtenus pour l'élimination de chaque type d'artéfact ainsi que pour la facilité d'interprétation des EEGs reconstruits.

Tout d'abord, nous nous focalisons sur les résultats obtenus pour l'élimination de l'artéfact oculaire.

L'EEG propre reconstruit à partir des sources informatives **identifiées par les expertes** et sa version débruitée ont obtenu la meilleure performance pour l'élimination de l'artéfact oculaire, avec 88% des EEGs qui présentent une élimination totale de l'artéfact oculaire (les méthodes d'inspection clinique et d'inspection clinique débruitée ont les mêmes résultats dans ce cas, étant donné que le débruitage n'apporte rien à l'élimination de l'artéfact oculaire). Le classificateur de Bayes suit avec la deuxième performance et en troisième position la méthode de la distance de Mahalanobis (table 5.1).

Ces résultats confirment les résultats obtenus dans la fenêtre de l'EEG inter-critique (tableau 3.7), où il est indiqué que le classificateur de Bayes est la meilleure méthode



**TABLE 5.1.** Performances de l'élimination de l'artéfact oculaire sur les EEG reconstruits sans artéfacts débruités (catégories : 1 aucun artéfact éliminé, 2 artéfacts éliminés partiellement, 3 aucun artéfact visible)

	Méthodes d'identification et débruitage			
catégorie	Inspection clinique	Inspection clinique	Distance de Mahalanobis	Classificateur de Bayes
	débruitage (seuillage SURE)			
3	88% (45)	88% (45)	47% (24)	69 % (35)
2	10% (5)	10% (5)	31% (16)	25% (13)
1	2% (1)	2% (1)	22% (11)	6% (3)

automatique pour l'élimination des l'artéfacts oculaires.

Les résultats obtenus pour l'élimination de artéfact de haute fréquence sont présentés dans le tableau 5.2.

**TABLE 5.2.** Performances de l'élimination des artéfacts de hautes fréquences sur les EEG reconstruits sans artéfact et débruités (catégories : 1 aucun artéfact éliminé, 2 artéfacts éliminés partiellement, 3 aucun artéfact visible)

	Méthodes d'identification et débruitage			
catégorie	Inspection clinique	Inspection clinique	Distance de Mahalanobis	Classificateur de Bayes
	débruitage (seuillage SURE)			
3	14% (7)	80% (41)	25% (13)	31 % (16)
2	76% (39)	20% (10)	55% (28)	65% (33)
1	10% (5)	0% (0)	20% (10)	4% (2)

Comme il a été montré précédemment par les résultats dans la fenêtre d'observation inter-critique, l'artéfact de haute fréquence (musculaire et/ou bruit) est l'artéfact le plus difficile à éliminer. En analysant les résultats du tableau 5.2 on constate que l'introduction de l'étape de débruitage améliore considérablement son élimination : par exemple, la méthode de l'inspection clinique passe de 14% à 80% pour l'élimination totale des artéfacts hautes fréquence. Quant aux méthodes automatiques, la méthode du classificateur de Bayes est plus performante que la distance de Mahalanobis.

Enfin, concernant l'élimination de l'artéfact d'ECG, aucun enregistrement d'EEG reconstruit après l'élimination d'artéfacts n'a été marqué avec la présence de l'artéfact d'ECG. On peut conclure que cet artéfact a été éliminé complètement. Cela confirme les résultats présentés dans les EEGs inter-critiques où les méthodes de l'inspection clinique, la distance de Mahalanobis et le classificateur de Bayes éliminent sans ambiguïté les artéfacts ECG.

Après l'analyse par type d'artéfacts, nous présentons les résultats des 4 EEGs comparés selon leur facilité d'interprétation dans le tableau 5.3. Selon les résultats présentés dans ce tableau, l'inspection clinique est la plus performante pour l'élimination des artéfacts dans le cas des EEGs critiques. On peut également remarquer que la facilité d'interprétation augmente entre les méthodes de cette inspection clinique et l'inspection clinique débruitée, cette dernière montrant une amélioration de 92% (47 EEGs sur 51 sont plus facilement interprétables), suivie du classificateur de Bayes avec une amélioration de l'interprétation de 88% (45 EEGs sur 51).

**TABLE 5.3.** Résultats de la classification sur les EEG reconstruits propres débruités selon leur facilité d'interprétation (catégories : 1 extrêmement pire, 2 pire, 3 égal, 4 mieux, 5 beaucoup mieux)

	Méthodes d'identification et débruitage			
catégorie	Inspection clinique	Inspection clinique	Distance de Mahalanobis	Classificateur de Bayes
	débruitage (seuillage SURE)			
5	12% (6)	65% (33)	24% (12)	25% (13)
4	74% (38)	27% (14)	51% (26)	63% (32)
3	6% (3)	0% (0)	19% (10)	6% (3)
2	0% (0)	0% (0)	0% (0)	0% (0)
1	8% (4)	8% (4)	6% (3)	6% (3)

L'amélioration qu'apporte l'élimination du bruit et des artéfacts engendre toutefois un coût. En effet, en contrepartie d'une meilleure interprétation, il est indéniable qu'il existe une perte ou une distorsion de l'information. L'élimination visuelle par inspection clinique conduit à une dégradation des 8% des EEGs (4 tracés sur 51). Après analyse, cette dégradation s'avère due à une perte d'information. Les deux méthodes automatiques conduisent, paradoxalement, à une perte d'information de 6% des EEGs (3 tracés). La perte d'information supplémentaire due au choix clinique des sources met en évidence

la difficulté, même pour les experts, d'aisément identifier les sources séparées. En effet, lors d'une analyse *a posteriori*, une source d'activité épileptique (ressemblant à une source d'artefact oculaire et donc mal classée à la première inspection) a été identifiée et replacée dans la classe *B*. Cette source, en revanche, avait été correctement classée comme *B* par les deux méthodes automatiques. En contrepartie, les deux méthodes ont éliminé beaucoup moins de sources d'artefacts.

La figure 5.1(a) montre un EEG critique brut perturbé par des artefacts oculaires et de haute fréquence. Cet EEG a été séparé et les sources estimées sont présentées dans la figure 5.1(b). Ces sources ont été classées (en différents types de sources d'artefacts et sources informatives) par les experts cliniques, comme indiqué dans la figure 5.1(b) : 4 sources d'artefact oculaire (les sources 1, 3, 15 et 21), 12 sources d'artefact de haute fréquence (les sources 6, 7, 8, 9, 12, 13, 14, 16, 17, 18, 20 et 24) et aucune source d'artefact d'ECG.

En comparant les 4 EEGs pré-traités (figures 5.2(a), 5.2(b) 5.3(a) et 5.3(b)) avec l'EEG critique brut (figure 5.1(a)) on voit qu'il y a clairement une amélioration et que l'activité de crise est nettement plus facile à interpréter. Cela est confirmé par les résultats présentés dans les tableaux 5.1, 5.2 et 5.3.

La figure 5.2(a) illustre l'EEG reconstruit à partir des sources identifiées comme sources informatives par l'inspection clinique (c'est-à-dire après élimination des 16 sources identifiées comme artefacts). L'amélioration est très claire, et on voit nettement les ondes lentes (activité theta principalement) dues à l'activité épileptique. Cet EEG reconstruit a été noté par les experts avec un score de 3 pour l'élimination de l'artefact oculaire, 2 pour l'élimination de l'artefact de haute fréquence et 4 selon la facilité d'interprétation.

La figure 5.2(b) montre l'EEG sans artefacts reconstruit à partir des sources identifiées comme sources informatives par l'inspection clinique débruitée, cet EEG a été noté par les experts avec un score de 3 pour l'élimination de l'artefact oculaire, 3 pour l'élimination de l'artefact de haute fréquence et 5 selon leur facilité d'interprétation (*i.e.* amélioration de l'élimination de AHF).

Les deux EEG reconstruits par des méthodes de classification supervisée automatiques montrent eux aussi une très bonne performance et une quasi totale élimination des artefacts. L'EEG propre reconstruit à partir des sources informatives identifiées par la méthode de la distance de Mahalanobis et débruité est montré dans la figure 5.3(a). Cette méthode a identifié les 4 sources d'artefacts oculaires (les sources 1, 3, 15 et 21) et 5 sources d'artefacts haute fréquence (les sources 12, 14, 18, 20 et 24) parmi les 16 sources d'artefact identifiées par les experts. Les sources non identifiées (AHF 6, 7, 8, 9, 13, 16 et


17) ont été classées dans la classe *B* (parmi les sources cérébrales). Cet EEG reconstruit a été noté par les experts avec 3 pour l'élimination de l'artéfact oculaire, 2 pour l'élimination de l'artéfact de haute fréquence et 4 selon la facilité d'interprétation.

L'EEG propre reconstruit à partir des sources informatives identifiées par le classificateur de Bayes et débruité est présenté dans la figure 5.3(b). Cette méthode a également identifié les 4 sources d'artéfacts oculaires (les sources 1, 3, 15 et 21) et elle a également identifié 7 sources d'artéfacts de haute fréquence (les sources 8, 12, 14, 16, 18, 20 et 24) parmi les 16 sources d'artéfact identifiées par les experts (2 sources de plus que la méthode de la distance de Mahalanobis). Les sources non identifiées (AHF 6, 7, 9, 13 et 17) ont été classées dans la classe *B*, comme dans le cas précédent. Cet EEG reconstruit a été noté par les experts avec 3 pour l'élimination de l'artéfact oculaire, 2 pour l'élimination de l'artéfact de haute fréquence et 4 selon leur facilité d'interprétation.


Comme on le voit, dans cet exemple, les deux méthodes automatiques ne font aucune fausse détection, mais plusieurs sources d'artéfacts restent non détectées.

Concernant l'élimination des artéfacts par inspection clinique, on constate que paradoxalement les EEGs critiques prétraités présentent de meilleurs résultats que les EEGs inter-critiques prétraités. Il nous semble que l'explication de ce fait est due à la procédure d'évaluation intellectuelle mise en oeuvre par les experts. En effet, face à l'EEG inter-critique les experts ont identifié (uniquement) les sources d'artéfacts les plus évidentes afin d'éviter l'élimination de sources informatives. Autrement dit, ils ont choisi les *sources non-informatives à éliminer*, les source cérébrales étant choisies par défaut comme celles non artéfactées. En revanche, dans le cadre de l'expertise des sources d'EEG critique, la démarche intellectuelle pour identifier les sources est très probablement et à juste titre différente : dans l'EEG critique les sources informatives les plus importantes, à ne pas éliminer, sont les sources d'activité épileptique, car l'épilepsie génère des signaux particulièrement énergétique au regard des signaux produits par des sources cérébrales induites par des procédures cognitives quelconques. Leur identification est relativement facile et sans ambiguïté, et donc dans ce cas les experts ont choisi plutôt les *sources informatives à garder*. Ce qui signifie que les sources d'artéfacts ont été écartées par défaut.

D'une manière globale, on peut conclure que les trois méthodes de classification (une visuelle et deux automatiques) sont assez performantes, car elles permettent l'élimination de la plupart des artéfacts et en conséquence une plus grande facilité d'interprétation. Toutefois, la méthode d'inspection clinique, combinée avec le débruitage, est la plus performante, suivie par le classificateur de Bayes. On peut observer aussi que même l'introduction d'une étape de débruitage améliore les résultats, en confirmant de cette



(a) EEG brut (début crise 350s) (voir aussi la figure A.14)




(b) sources estimées (voir aussi la figure A.15)


**FIGURE 5.1.** EEG brut et sources estimées après SAS. Les artéfacts identifiés par les experts sont indiqués sur la figure. Les différentes méthodes de classification ont identifié les sources suivantes :

- distance de Mahalanobis 1, 3, 15 et 21 (AO), 12, 14, 18, 20 et 24 (AHF)
- classificateur de Bayes : 1, 3, 15 et 21 (AO), 8, 12, 14, 16, 18, 20 et 24 (AHF)

façon les résultats présentés pour les EEGs inter-critiques. Autrement dit, les signaux EEG extraits sur des fenêtres d'observation critique peuvent être prétraité selon la même procédure que les signaux obtenus en phase inter-critique.



(a) inspection clinique (noté 4 selon leur facilité d'interprétation) (voir aussi la figure A.16)




(b) inspection clinique débruité (noté 5 selon leur facilité d'interprétation) (voir aussi la figure A.17)


**FIGURE 5.2.** EEG reconstruits après identification et élimination des artéfacts. On remarque une diminution du bruit pour le deuxième tracé, visible spécialement sur les 5 dernières électrodes (F7-P9).

#### 5.1.4 Performances de classification : sources cérébrales

Malgré les bonnes performances obtenues précédemment, une perte d'information (élimination de sources informatives) est à regretter sur certains tracés. La procédure d'identification des sources informatives dans le cadre de fenêtres d'observation critiques



(a) distance de Mahalanobis débruité (noté 4 selon leur facilité d'interprétation) (voir aussi la figure A.18)



(b) classificateur de Bayes débruité (noté 4 selon leur facilité d'interprétation) (voir aussi la figure A.19)

**FIGURE 5.3.** EEG reconstruits après identification et élimination des artéfacts. On remarque une meilleure reconstruction dans deuxième cas, visible surtout pour la première électrode (FP2).

peut-elle être améliorée ?

Parmi les sources de 51 enregistrements (1224 sources), 288 sources ont été identifiées par les experts cliniques comme sources informatives. Ces sources devraient donc être classées dans la classe *B* par les méthodes automatiques. Le tableau 5.4 montre les valeurs de *Sen* et de *TFP* obtenues par les deux méthodes de classification automatique (le classificateur de Bayes et la méthode basée sur la distance de Mahalanobis) pour la

classification de sources informatives.

**TABLE 5.4.** Identification des sources informatives par les méthodes de classification de la distance de Mahalanobis et le classificateur de Bayes.

	Distance de Mahalanobis	Classificateur de Bayes
$Sen_B$	0.8819 (254/288)	0.8194 (235/288)
$TFP_B$	0.3387	0.2545

Nous rappelons que les valeurs de  $Sen$  indiquent les sources informatives bien identifiées et les valeurs de  $TFP$  indiquent les sources d'artéfacts qui ont été classées dans la classe  $B$ . Comme nous nous intéressons aux causes de la perte d'information dans les EEGs reconstruits, seules les valeurs de sensibilité seront discutées.

En analysant le tableau, on observe que la méthode basée sur la distance de Mahalanobis a la valeur de  $Sen$  la plus élevée avec 88.19% (254/288) de sources informatives bien identifiées. De fait, la question qui vient est : dans quelle classe ont été classées les 11.91% (34/288) de sources informatives non identifiées ? Après analyse, nous avons trouvé que :


- 24 sources ont été classées dans la classe  $AO$ ,
- 9 sources ont été classées dans la classe  $AHF$  et
- une source a été classée dans la classe  $AECG$ .

Quant au classificateur de Bayes, la valeur de  $Sen$  indique que 81.60% (236/288) sources informatives ont été bien identifiées. Les 18.4% (52/288) sources informatives non identifiées ont été classées comme suit :

- 42 sources ont été classées dans la classe  $AO$ ,
- 9 sources ont été classées dans la classe  $AHF$  et
- une source a été classée dans la classe  $AECG$ .

Ces chiffres montrent que le classificateur de Bayes est le plus performant pour l'élimination des  $AO$  (très bonne sensibilité), mais le prix à payer est l'inclusion d'autres sources parmi ces artéfacts. Mais un autre aspect est encore plus important : pour les EEG inter-critiques, les sources de la classe  $B$  et de la classe  $AHF$  étaient très proches, et les éventuelles confusions de classement apparaissaient entre ces deux classes. En revanche, dans le cas de l'EEG critique (figure 5.4), les sources informatives sont confondues avec les sources d'artéfact oculaire. La cause est la nature particulière de ces sources cérébrales. En fait, parmi les sources estimées classées comme informatives par les médecins, il apparaît un nouveau type de source : les sources d'activité épileptique (figure






**FIGURE 5.4.** EEG critique brut (début crise 350s) (voir aussi la figure A.20)

5.5(a)).


Les sources d'activité épileptique ont un contenu fréquentiel principalement localisé dans la bande theta (figure 5.5(b)), mais aussi, parfois, dans la bande delta. De plus, ces sources sont fortement propagées, étant présentes avec des amplitudes relativement fortes sur plusieurs électrodes de surface. Donc, comme certaines sources d'activité épileptique ont une forte présence fréquentielle dans la bande delta et possèdent des forts coefficients de reconstruction, elles risquent d'être confondues avec les sources d'artéfact oculaire (du moins par rapport aux caractéristiques que nous avons choisies et validées dans le cas inter-critique).

Une amélioration de l'étape de classification est donc nécessaire afin de conserver, si possible, *toutes* les sources informatives : les sources d'activité cérébrale de fond et les sources d'activité épileptique.

Il est clair que, pour classer un ensemble hétérogène, il est plus judicieux de proposer une classification en plusieurs classes, avec des caractéristiques adaptées aux données. Une première solution possible est donc l'introduction d'une classe supplémentaire pour la classification automatique de sources, contenant uniquement les sources d'activité épileptique (SC). A partir des sources identifiées par les experts, un nouvel ensemble d'apprentissage peut être créé et la classification peut être améliorée. Avec cette nouvelle classe, les sources dues à l'activité cérébrale de fond seront *a priori* classées dans la classe B et les sources d'activité épileptique dans la classe SC. Pour obtenir un tracé d'EEG sans artéfacts, la reconstruction sera faite avec les sources de ces deux classes.



(a) sources estimées



(b) spectres

FIGURE 5.5. Source estimées après SAS.

### 5.1.5 Classification en 5 classes

**L'ensemble d'apprentissage.** Pour l'introduction de cette nouvelle classe, plusieurs sources de crise ont été ajoutées à l'ensemble d'apprentissage présenté dans la sous-section précédente). Les experts ont identifié les sources de crise sur les 51 enregistrements et les sources de crise de 25 d'entre eux ont été utilisées pour l'ensemble d'apprentissage.

**L'ensemble de test.** Afin d'évaluer la performance de la classification des sources de crise, les sources séparées de 26 enregistrements (non utilisés pour l'ensemble d'apprentissage) ont été utilisées pour l'ensemble de test.

#### 5.1.5.1 Résultats de la classification

Pour l'identification des sources d'activité épileptique, nous avons utilisé les deux méthodes de classification utilisés dans l'étape précédente : la distance de Mahalanobis et le classificateur de Bayes.

Dans un premier temps, nous présentons les résultats de la classification de sources de crise  $SC$  et, dans un deuxième temps, les résultats de la classification de sources informatives c'est-à-dire les sources d'activité cérébrale (activité de fond  $B$ ) + activité épileptique  $SC$ ).

Les résultats obtenus pour l'identification de sources d'activité épileptique par les deux méthodes d'identification automatique sont présentés dans le tableau 5.5 ( $Sen_{SC}$  et  $TFP_{SC}$ ).

D'après le tableau 5.5, la méthode de classification basée sur la distance de Mahalanobis présente une bonne performance sur le groupe d'apprentissage, mais une mauvaise performance pour le groupe de test. Quant au classificateur de Bayes, il présente les meilleures performances en  $Sen_{SC}$  pour les deux groupes d'apprentissage et de test. Les deux méthodes conduisent à très peu de fausses détections (petite valeur de  $TFP_{SC}$ ).

Les résultats de sensibilité et spécificité pour la classe  $SC$  indiquent que la méthodologie de classification est relativement adaptée à ces sources : même si les performances sont moins bonnes que pour la classification des sources en inter-critique (artéfacts notamment), elles restent correctes. Cela dit, ces résultats sont secondaires. Si, par exemple, une source de crise non détectée est "mal" classée dans la classe  $B$ , l'EEG résultant final sera correct, car la reconstruction est faite à partir de toutes les sources informatives,  $B$  et  $SC$  inclus.

**TABLE 5.5.** Identification des sources de crise par les méthodes de classification de la distance de Mahalanobis et le classificateur de Bayes sur les deux groupes de apprentissage et de test.

	Distance de Mahalanobis	Classificateur de Bayes
	<b>Ensemble d'apprentissage</b>	
<b>Sen<sub>SC</sub></b>	0.8036	0.8571
<b>TFP<sub>SC</sub></b>	0.0445	0.0471
	<b>Ensemble de test</b>	
<b>Sen<sub>SC</sub></b>	0.4909	0.7455
<b>TFP<sub>SC</sub></b>	0.0163	0.0188

Le tableau 5.6 montre les valeurs de *Sen* et de *TFP* de l'ensemble de sources informatives après la classification en 5 classes : les sources d'activité cérébrale identifiées dans la classe *B* et les sources d'activité épileptique identifiées dans la classe *SC* sont réunies dans la classe *BSC*. En comparant ces résultats avec les résultats obtenus par la classe *B* de la classification en 4 classes (tableau 5.4), on observe une augmentation pour les valeurs de *Sen*, c'est-à-dire une meilleure identification des sources informatives.

**TABLE 5.6.** Identification des sources informatives (classe SCB = classe B + classe SC) par les méthodes de classification de la distance de Mahalanobis et le classificateur de Bayes.

	Distance de Mahalanobis	Classificateur de Bayes
<b>Sen<sub>SCB</sub></b>	0.9236 (266/288)	0.8785 (253/288)
<b>TFP<sub>SCB</sub></b>	0.3579	0.2703

En exploitant une classification en 5 classes, la méthode basée sur la distance de Mahalanobis a bien identifié 92.36%(266/288) de sources informatives. Seulement 7.64% (22/288) des sources informatives restent non identifiées. Celles-ci ont été classées comme suit :

- 13 sources ont été classées dans la classe *AO*,
- 8 sources ont été classées dans la classe *AHF*,
- une source a été classée dans la classe *AECG*

L'introduction d'une nouvelle classe (*SC*) a donc permis de "récupérer" 8 sources qui

étaient classées comme sources d'artefacts (7 sources dans la classe *AO* et une source dans la classe *AHF*).

Quant au classificateur de Bayes, la valeur de *Sen* montre que 87.85% (254/288) de sources informatives ont été bien identifiées. Notamment, l'introduction d'une nouvelle classe (*SC*) a permis de "récupérer" 18 sources qui étaient classées comme sources d'artefacts dans la classe *AO*. Les 12.15% de sources restantes sont réparties comme indiqué ci-dessous :

- 21 sources ont été classées dans la classe *AO*
- 9 sources ont été classées dans la classe *AHF*
- une source a été classée dans la classe *AECG*


Pour comparer les deux approches (classification en 4 classes et classification en 5 classes), nous présentons un exemple de signaux d'EEG reconstruit dans les figures suivantes. La figure 5.6(a) montre un EEG brut avec une activité épileptique (des ondes lentes principalement dans la bande delta), et la figure 5.6(b) montre les sources estimées après la SAS. Selon les indications des experts, les sources d'activité cérébrale de fond (*B*) sont les sources 3, 4, 7, 11, 15, 21 et 23 et les sources d'activité épileptique (*SC*) sont les sources 1, 2 et 5.

La reconstruction à partir des sources de la classe *B* (classification en 4 classes) et par la classe *B* + la classe *SC* (5 classes) est montrée dans les figures suivantes.


L'EEG reconstruit par la classe *B* (4 classes) par la méthode de la distance de Mahalanobis est montré dans la figure 5.7. Il est à remarquer que cet EEG a été noté avec une perte d'information par les experts cliniques. En effet, cette méthode a identifié comme sources informatives les sources 3, 4, 7, 11, 15 et 21, mais aucune source d'activité épileptique n'a été classée parmi les sources informatives. Les 3 sources *SC* ont été en fait classées dans la classe *AO*, une perte d'information est donc évidente. Pour cet exemple de tracé, l'EEG reconstruit après le classificateur de Bayes est identique à celui de la figure 5.7, donc cette solution est aussi notée par les médecins avec une perte d'information.

L'EEG reconstruit par les sources informatives issues de la classification en 5 classes (sources d'activité cérébrale et sources d'activité épileptique *BSC*) dont les sources sont identifiées par la méthode de la distance de Mahalanobis est montré dans la figure 5.8(a). Plus en détails, les sources d'activité cérébrale de fond identifiées par cette méthode (classe *B*) sont 3, 4, 7, 11, 15, 21 et 23. Toutes les sources d'activité épileptique (classe *SC*) ont été identifiées (1, 2 et 5). Une seule source d'activité cérébrale n'a pas été identifiée, en comparaison de la classification en 4 classes, la perte d'information est donc minimale.

La figure 5.8(b) montre L'EEG reconstruit par les sources informatives (sources d'ac-




(a) EEG brut (début crise 364s) (voir aussi la figure A.21)



(b) Sources estimées par SAS (voir aussi la figure A.22)

**FIGURE 5.6.** EEG avec activité épileptique

tivité cérébrale et sources d'activité épileptique *BSC*) identifiées par le classificateur de Bayes. Les sources d'activité cérébrale identifiées par cette méthode sont moins nombreuses (classe *B* : 3, 4, 7, 11, 15 et 21), comme d'ailleurs les sources d'activité épileptique (classe *SC* : 1 et 2). Dans ce cas, une source d'activité cérébrale et une source d'activité épileptique n'ont pas été identifiées, et une perte d'information est encore présente (et cette perte, même réduite, risque d'être très dommageable pour le diagnostic, car une des sources d'épilepsie est ignorée dans la reconstruction).




**FIGURE 5.7.** EEG reconstruit par les sources identifiées dans la classe B (4 classes, distance de Mahalanobis) (voir aussi la figure A.23)


Les résultats de classification présentés montrent, en général, que la méthode basée sur la distance de Mahalanobis est plus performante que le classificateur de Bayes du point de vue de la préservation de l'information. Cependant, les résultats de la validation médicale indiquent que le classificateur de Bayes est en moyenne plus performant. Cela peut s'expliquer par le fait que la méthode basée sur la distance de Mahalanobis a une valeur très élevée de *TFP*, c'est-à-dire que, même si les sources informatives sont bien identifiées, plusieurs sources d'artéfacts ont été classées comme sources informatives. Autrement dit, les sources d'artéfacts restantes parmi les sources cérébrales perturbent l'interprétation. Au contraire, le classificateur de Bayes a une valeur inférieure de *TFP*, c'est-à-dire beaucoup moins de sources d'artéfact sont classées parmi les sources cérébrales. Les EEG reconstruits avec les sources cérébrales identifiées par le classificateur de Bayes sont donc moins perturbés par les artéfacts. Cela confirme les résultats obtenus dans le chapitre 3.

D'une manière générale, on peut conclure que la reconstruction d'EEG à partir de sources classées dans la classe B et la classe SC semble une bonne solution afin d'éviter l'élimination de sources informatives. Cependant une perte d'information est encore présente, et l'étape de classification doit être améliorée avant une implémentation clinique. Les variables explicatives extraites pour la classification des sources d'artéfacts n'ont pas été modifiées et enrichies dans cette dernière partie pour l'identification des sources épileptiques.

Deux choix nous semblent possibles, le premier porte sur l'ensemble d'apprentissage.



(a) distance de Mahalanobis (voir aussi la figure A.24)



(b) classificateur de Bayes (voir aussi la figure A.25)

**FIGURE 5.8.** EEG reconstruit par les sources identifiées dans la classe B et les sources identifiées dans la classe SC (5 classes)

En fait, l'ensemble utilisé pour obtenir ces résultats est assez réduit en ce qui concerne les sources épileptiques, et une bonne approche serait d'augmenter le nombre de sources d'activité épileptique sur l'ensemble d'apprentissage. De plus, dans l'ensemble d'apprentissage actuel, la plupart des sources d'activité épileptique sont puissantes principalement dans la bande theta. Le groupe de sources épileptiques peut être enrichi des variables explicatives caractérisant l'information dans la bande delta. Cette approche pour-



rait diminuer les confusions *AO - SC* encore présentes et donc améliorer la classification. Une autre possibilité serait de créer plusieurs classes parmi les sources informatives (pas uniquement *B* et *SC*, mais subdiviser la classe *SC* en fonction du type d'activité épileptique constatée.

Enfin, un troisième choix porte sur l'amélioration des caractéristiques décrivant les sources, voire sur l'implémentation d'autres algorithmes de classification. Ces travaux constituent une perspective de recherche intéressante et prometteuse.

## 5.2 Application des algorithmes de synchronisation

Cette deuxième partie illustre une autre application possible de la méthodologie de pré-traitement développée précédemment, notamment l'amélioration de certaines méthodes d'analyse automatique de l'EEG. En particulier, ici, les méthodes automatiques concernent la caractérisation de la crise d'épilepsie par l'analyse de synchronisation sur des signaux d'EEG du scalp.

En effet, il s'avère que les outils d'estimation de relations inter-sinaux tels que l'interspectre, la cohérence et d'autres méthodes dérivées, lorsqu'ils sont appliqués sur des signaux EEG de profondeur, permettent la mise en évidence de relations inter-structures cérébrales [Wendling *et al.*, 2001]. En suivant une démarche similaire, des travaux plus récents ont montré que les synchronisations électrophysiologiques de surface pouvaient aussi être estimées et exploitées pour caractériser la crise d'épilepsie [Astolfi *et al.*, 2007]. La justification d'une telle démarche peut être résumée par le fait que les signaux de surface recueillent l'activité électrique sous-jacente à chaque électrode, les relations inter-sinaux peuvent fournir des informations plus pertinentes sur les structures cérébrales mises en jeu, génératrices des sources de profondeur projetées sur le scalp. La dimension spatiale peut alors être prise en compte et plus particulièrement la directivité des sources sous-jacentes.

Cependant, l'interprétation de ces relations d'EEG de surface reste délicate. En effet contrairement au signaux SEEG (de profondeur), les EEG de surface sont particulièrement perturbés par des sources électrophysiologiques externes (artéfacts et bruit) et ce phénomène est d'autant plus accentué sur des signaux enregistrés lors des crises d'épilepsie<sup>18</sup>. D'ailleurs, très souvent, lors de l'analyse visuelle, l'expert ne peut pas analyser les signaux critiques, car ils sont noyés sous les artéfacts musculaires de haute fréquence

---

18. Le comportement souvent tonique des patients lors de la survenue de crise engendre sur les signaux des perturbations beaucoup plus énergétiques.

liés à l'hyper-tonicité. Par ailleurs, un certain nombre de crises s'accompagnent de mouvements oculaires.

Bien souvent, ces perturbations sont propagées sur plusieurs électrodes, et de fait génèrent également des synchronisations inter-sinaux. Les relations détectées en surface peuvent donc être dues aux artéfacts et non à l'information des sources de profondeurs. Ceci nuit à la caractérisation et donc à l'aide au diagnostic. L'élimination d'artéfacts apporterait un éclairage nouveau sur la caractérisation de la crise d'épilepsie et à la localisation de sources à partir de l'estimation de relations inter-sinaux d'EEG de surface.

### 5.2.1 Méthodes d'estimation de relations inter-voies

Les neurosciences ont reconnu depuis longtemps [Berger, 1929] l'importance des concepts telle que la connectivité et le degré de synchronisation dans le cerveau (*i.e.* les réseaux de communication inter-structures anatomiques) et elles ont également mesuré leur importance dans la compréhension du comportement organisé des régions corticales au-delà d'une simple cartographie de leurs activités fonctionnelles cérébrales [Astolfi *et al.*, 2007]. Les synchronisations électrophysiologiques entre différentes structures cérébrales sont à l'origine de certains fonctionnements neuro-physiologiques sains ou pathologiques [Bartolomei *et al.*, 2001; Bartolomei *et al.*, 2004; Arnhold *et al.*, 1999; Lehnertz *et al.*, 2001; Zavaglia *et al.*, 2008; Astolfi *et al.*, 2008].

En particulier, les sources électrophysiologiques d'épilepsie situées dans une zone épileptogène peuvent être caractérisées par la synchronisation anormale et excessive d'une population de neurones [Arnhold *et al.*, 1999]. Cette population, qui peut être modélisée comme le générateur d'une source intra-cérébrale, peut se mettre en relation avec d'autres zones anatomiques cérébrales au cours du déroulement d'une crise et parfois se généraliser à l'ensemble. La localisation des sources et l'état des communications inter-structures constituent l'information recherchée et exploitée par le neurologue pour fonder son diagnostic.

On peut distinguer dans la bibliographie deux grandes familles de méthodes d'estimation de la connectivité : paramétriques (basées sur une modélisation de type AR) et non paramétriques (basées directement sur des caractéristiques statistiques des signaux). La plupart de ces méthodes permettent une analyse fréquentielle des connectivités, en quantifiant la manière dont deux signaux sont synchronisés par bande de fréquence. Une analyse détaillée de ces méthodes dépasse l'objectif de cette thèse. Nous allons donc présenter des résultats relatifs aux couplages inter-sinaux sur des EEG réels basés sur des

estimateurs de connectivité relativement basiques : l'inter-spectre et la cohérence.

Par définition, l'inter-spectre est la transformée de Fourier de la fonction d'inter-corrélation de deux signaux  $x_1$  et  $x_2$  (supposés de moyenne nulle). En notant l'inter-corrélation :

$$R_{x_1x_2}(\tau) = \mathbb{E}(x_1(t)x_2(t - \tau)) \quad (5.1)$$

où  $\mathbb{E}$  représente l'espérance mathématique, l'inter-spectre (CPSD, *cross power spectral density*) sera obtenu comme :

$$S_{x_1x_2}(f) = \int_{-\infty}^{+\infty} R_{x_1x_2}(\tau)e^{-i2\pi f\tau} d\tau \quad (5.2)$$

La cohérence ( $C$ ) est la plus connue des mesures de synchronisation inter-signaux. Elle est obtenue en normalisant l'inter-spectre (5.2) par les densités spectrales de puissance des deux signaux d'intérêt :

$$C_{x_1x_2}(f) = \frac{|S_{x_1x_2}(f)|}{\sqrt{|S_{x_1x_1}(f)||S_{x_2x_2}(f)|}} \quad (5.3)$$

Les valeurs de  $C$  sont normalisées entre 0 et 1 et indiquent le degré de corrélation linéaire existant entre les signaux, comme une fonction de la fréquence. Si à une fréquence donnée la valeur de  $C$  est proche de 0, cela signifie que les signaux sont linéairement indépendants à cette fréquence. Inversement, une valeur proche de 1 signifie une grande dépendance linéaire entre eux à la fréquence en question ou à la bande de fréquence souhaitée. La cohérence  $C$  est une fonction positive et "commutative" quelle que soit la fréquence, c'est-à-dire  $C_{x_1x_2}(f) = C_{x_2x_1}(f)$ .

### 5.2.2 Effet du prétraitement sur les relations inter-voies d'EEG réels

Comme précisé précédemment, la présence des mêmes artefacts, propagés sur plusieurs voies d'EEG, augmente leur synchronisation, du moins dans les bandes de fréquence des artefacts en question (plutôt *delta* pour les artefacts oculaires, plutôt *beta* ou *gamma* pour les artefacts musculaires de haute-fréquences). L'objectif de cette sous-section est de présenter des résultats d'estimation de synchronisation (inter-spectre et cohérence) sur des exemples d'EEG bruts et pré-traités. Une analyse sur l'ensemble de la base de données, nécessaire pour quantifier l'utilité du pré-traitement proposé, dépasse le cadre de cette thèse (voir pour plus de détails [Vélez-Pérez, 2010; Romo-Vázquez *et al.*, 2009]).

Pour illustrer l'effet du pré-traitement, nous avons choisi les fenêtres de 20 secondes utilisées précédemment :

- fenêtre inter-critique d'activité normale ;
- fenêtre pathologique, avec le début de crise indiqué par les médecins à la seconde 10.

Les figures 5.9(a), 5.9(b) et 5.9(c) montrent respectivement l'EEG brut, la cohérence et l'inter-spectre pour deux voies de l'EEG (T4 et P10). L'EEG est contaminé par des artéfacts oculaire et de haute fréquence. En analysant la figure 5.9(b) on observe que la cohérence est relativement élevée dans les bandes fréquentielles *delta*, *theta* et *alpha* [0.5 10Hz]. La figure 5.9(c), qui représente l'inter-spectre de ces deux mêmes voies, montre que la synchronisation se trouve essentiellement dans la bande *theta*<sup>19</sup>.


Les deux mêmes voies après prétraitement<sup>20</sup> sont présentées dans les figures suivantes. En comparant les voies T4 et P10 de l'EEG brut (figure 5.9(a)) et l'EEG sans artéfacts (figure 5.10(a)), on observe l'élimination quasi complète de l'artéfact oculaire et la réduction de l'artéfact de haute fréquence. L'analyse de la cohérence 5.10(b) de deux voies T4 et P10 sans artéfact montre une corrélation sur ces voies sur toutes les bandes de fréquence, c'est-à-dire une similitude des deux signaux. Cependant aucune indication de l'énergie de chaque bande fréquentielle n'est donnée (valeurs normalisées). En revanche, l'inter-spectre des deux voies 5.10(c) montre des fréquences communes surtout dans les bandes *theta* et *alpha*, avec une faible énergie dans la bande *delta* et la quasi-disparition de la bande *beta*.

En comparant la cohérence de l'EEG brut (figure 5.9(b)) avec la cohérence de l'EEG pré-traité (figure 5.10(b)), on observe que l'élimination d'artéfacts conduit à une cohérence dans toutes les bandes de fréquence. En revanche, l'analyse de l'inter-spectre de l'EEG brut (figure 5.9(c)) et l'inter-spectre de l'EEG sans artéfacts (figure 5.10(c)) indique que la synchronisation dans les bandes *theta* et *alpha* est préservée, mais que, au contraire, la synchronisation dans la bande *delta*, correspondant aux fréquences contenues dans les sources d'artéfacts oculaires éliminées, diminue considérablement. Donc, on peut considérer que la diminution de la synchronisation dans la bande *delta* est due à l'élimination de l'artéfact oculaire. On peut remarquer aussi une légère diminution de la synchronisation de la bande *beta*, due à l'élimination de l'artéfact de haute fréquence.


---

19. En fait, la normalisation implicite dans la cohérence met en évidence l'existence des fréquences synchronisées quelle que soit leur énergie, alors que l'inter-spectre accentue les fréquences les plus énergétiques.

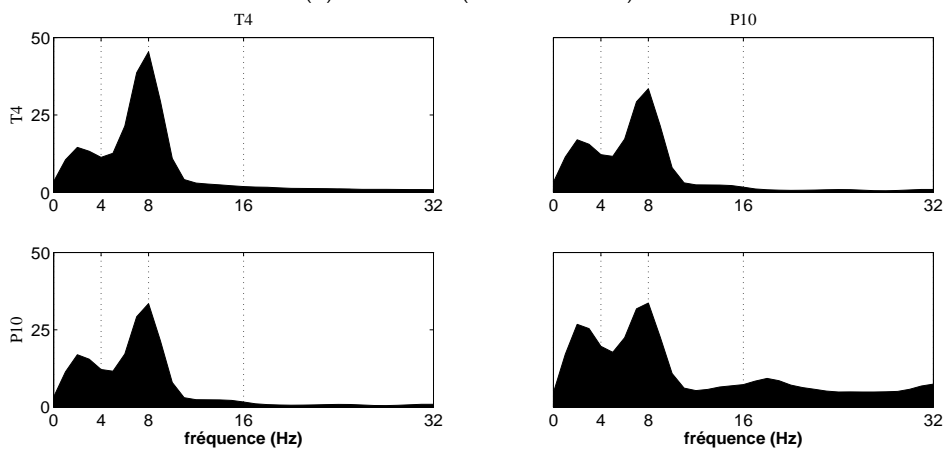
20. EEG reconstruit par la méthode de classification basé sur la distance de Mahalanobis, la méthode la plus performante pour l'EEG inter-critique



(a) EEG brut (voir aussi la figure A.7)




(b) Cohérence (voies T4 et P10)




(c) densité spectrale et inter-spectre (voies T4 et P10)

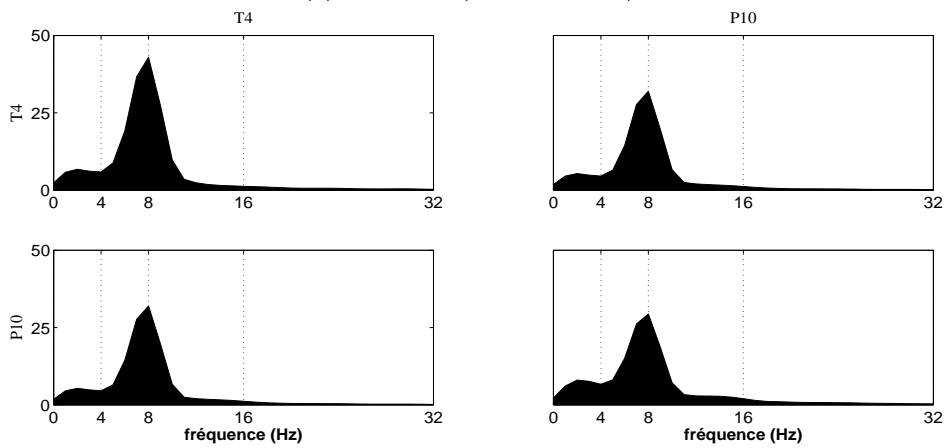
**FIGURE 5.9.** EEG brut inter-critique



(a) EEG sans artéfacts débruité (distance de Mahalanobis) (voir aussi la figure A.13)



(b) Coherence (voies T4 et P10)



(c) densité spectrale et l'inter-spectre (voies T4 et P10)

**FIGURE 5.10.** EEG sans artéfacts inter-critique

Les exemples précédents indiquent que l'inter-spectre permet de mieux analyser les relations entre les signaux, à la fois en termes de contenu fréquentiel et énergétique. Pour illustrer ce propos et dans un souci de clarté, seuls les résultats obtenus avec l'inter-spectre seront présentés en ce qui concerne le traitement des signaux prélevés lors de crises d'épilepsie

La figure 5.11(a) montre un EEG critique brut fortement perturbé par des artéfacts oculaires. Dans cet EEG, nous avons analysé les voies T5 et FT9<sup>21</sup>. On peut observer sur ces deux voies la présence d'une activité épileptique (à partir du début de la crise 10s) ainsi que des artéfacts oculaires et haute fréquence. La figure 5.11(b) montre la densité spectrale pour chaque voie ainsi que leur inter-spectre<sup>22</sup>. Dans cette figure, on peut remarquer une très forte synchronisation dans la bande *delta* et également une forte synchronisation dans la bande *theta* même si elle est toutefois moindre intensité que dans *delta*.


Nous avons appliqué la méthodologie automatique d'élimination d'artéfacts sur cet EEG critique (figure 5.11(a)) pour obtenir l'EEG sans artéfacts (figure 5.12(a)). La méthode d'identification automatique utilisée a été le classificateur de Bayes, la méthode la plus performante pour l'élimination d'artéfacts concernant l'EEG critique (voir section précédente). A partir de ce traitement, on peut observer la quasi-totalité de l'élimination d'artéfacts oculaires. Les spectres des voies T5 et FT9 de l'EEG sans artéfacts, ainsi que leur inter-spectre sont présentés dans la figure 5.12(b). En analysant cette figure, on peut remarquer que leurs synchronisations sont pratiquement dominées par la bande *theta* seulement, donc que les synchronisations dues aux artéfacts ont été éliminées.

L'exemple présenté ci-dessus illustre le fait que le pré-traitement permet de se focaliser sur les synchronisations d'intérêt, c'est-à-dire les synchronisations dues à la mise en œuvre du réseau de communication électrophysiologiques fonction de la localisation des sources pathologiques. Ceci suggère une autre application possible, à savoir la détection de leur présence, à la fois du point de vue fréquentiel (quelle bande est la plus représentée), temporel (à partir de quel moment ces synchronisation apparaissent) et spatial (quelles sont les voies d'EEG impliquées et sur quel hémisphère correspondant). Pour illustrer cette application, nous avons analysé plus en détails l'EEG critique en découpant le signal sur deux fenêtres : la fenêtre [0s 10s], c'est-à-dire avant le début de la crise, et la fenêtre [10s 20s], c'est-à-dire pendant la dynamique de la crise. L'évolution des me-

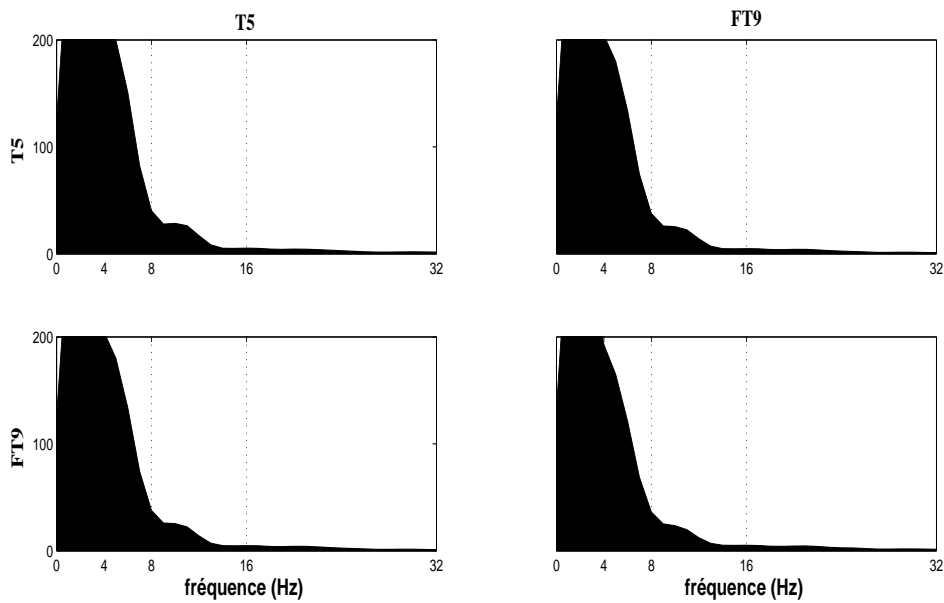
---

21. L'EEG analysé correspond à une crise développée dans l'hémisphère gauche.

22. Comme indiqué précédemment l'activité épileptique (des crises temporales) est caractérisée par un contenu fréquentiel dans la bande *theta* principalement.



(a) EEG brut (début crise 350s) (voir aussi la figure A.26)




(b) densité spectrale et l'inter-spectre (voies T5 et FT9)

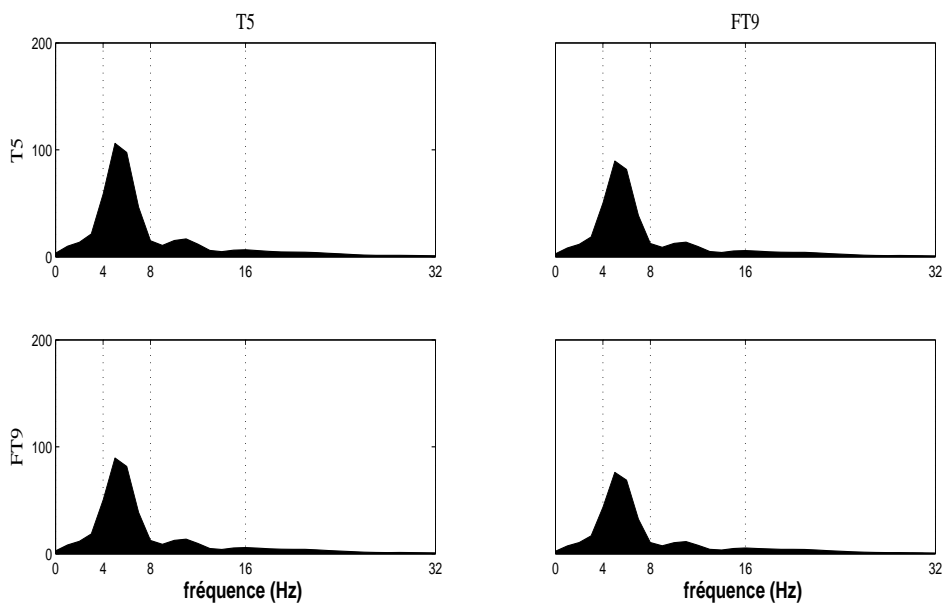
**FIGURE 5.11.** EEG brut critique

sures de synchronisation entre les différentes voies de l'EEG permettront d'évaluer la mise en place d'un réseau épileptique (certaines régions se synchronisent *au moment de la crise, fortement et pour des fréquences caractérisant la décharge critique*. Nous présentons l'analyse spectrale et la synchronisation sur sept voies pour chaque hémisphère (gauche





(a) EEG sans artéfacts débruité (classificateur de Bayes) (voir aussi la figure A.19)



(b) densité spectrale et l'inter-spectre (voies T5 et FT9)

**FIGURE 5.12.** EEG sans artéfacts critique

et droit) choisies par les experts cliniques comme les plus représentatives pour l'analyse d'une crise épileptique temporelle :

- hémisphère gauche : Fp1, O1, F7, T3, T5, FT9 et P9 ;
- hémisphère droit : Fp2, O2, F8, T4, T6, FT10 et P10

L'analyse de la connectivité sur l'EEG brut pour les deux hémisphères est détaillée dans les figures 5.13(a), 5.15(a), 5.13(b) et 5.15(b) :

- les figures 5.13(a) (hémisphère gauche) et 5.15(a) (hémisphère droit) montrent l'inter-spectre des sept voies dans la fenêtre de 10 s immédiatement avant la crise. D'après ces figures, on peut remarquer une forte synchronisation sur toutes les voies dans la bande *delta* (un peu moins pour la voie Fp1), et une synchronisation moins forte dans la bande *theta* ;
- les figures 5.13(b)(hémisphère gauche) et 5.15(b)(hémisphère droit) montrent l'inter-spectre des sept voies dans la fenêtre pendant la crise. D'après ces figures on peut constater une forte synchronisation en ce qui concerne toutes les voies dans la bande *delta* (comme dans la fenêtre précédente) et une forte augmentation de la synchronisation dans la bande *theta*, par rapport à la fenêtre précédente, ainsi que l'apparition d'une légère synchronisation dans la bande *alpha*. Cette augmentation de la synchronisation dans la bande *theta* est très probablement due à l'apparition de l'activité épileptique.

L'analyse spectrale a été également réalisée sur les deux fenêtres de l'EEG pré-traités (figure 5.12(a)) pour les deux hémisphères pour les mêmes sept voies :

- les figures 5.14(a) (hémisphère gauche) et 5.16(a) (hémisphère droit) présentent la connectivité (à travers l'inter-spectre) des sept voies dans la fenêtre avant la crise. Dans ces figures, on peut observer qu'il n'y a pas de synchronisation importante entre les voies, du moins pas suffisamment énergétique (les échelles des axes dans les figures avant/après début de la crise et avant/après pré-traitement sont identiques). On peut constater que l'élimination d'artéfacts oculaires fait disparaître toutes les fausses synchronisations dans la bande *delta*, qui étaient présentes sur l'analyse de l'EEG brut dans la même fenêtre (figures 5.13(a) et 5.15(a)) ;
- quant à l'analyse spectrale sur la fenêtre pendant la crise (figures 5.14(b) (hémisphère gauche) et 5.16(b) (hémisphère droit)) on peut observer une synchronisation sur la bande *theta* présentes sur toutes les voies, cependant plus forte sur les voies F7, T3, T5, FT9 et P9 pour l'hémisphère gauche et sur les voies F8, T4, T6, FT10 et P10 pour l'hémisphère droit, car ces électrodes sont situées sur le lobe temporal, ainsi qu'une légère synchronisation dans la bande *alpha*. En comparant avec l'analyse sur l'EEG brut pour la même fenêtre, on constate la disparition des synchronisations sur la bande *delta* dues aux artéfacts oculaires.

Un autre constat à propos de l'analyse spectrale sur la fenêtre de crise est que les voies de l'hémisphère gauche (figure 5.14(b)) sont beaucoup plus synchronisées

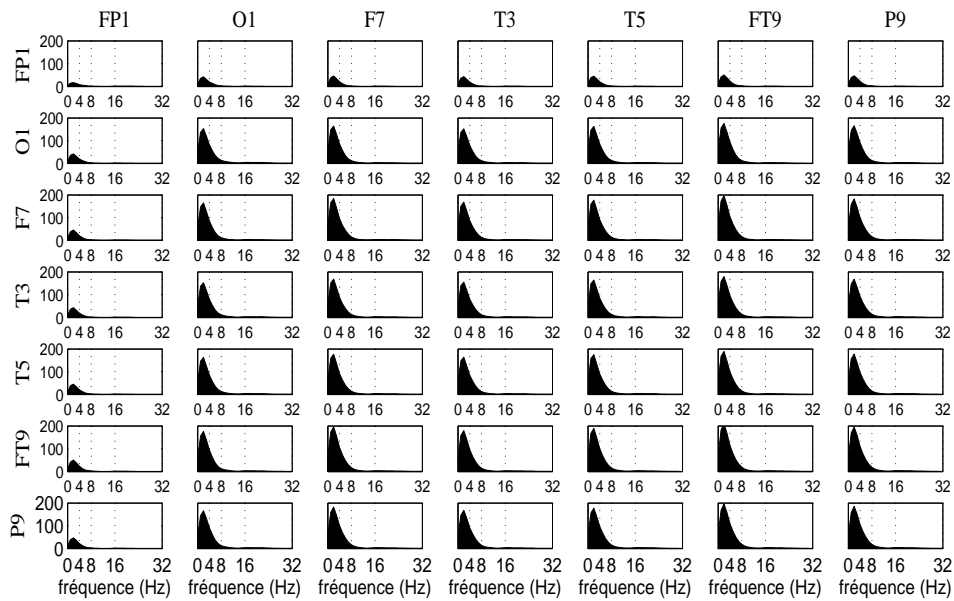
et énergétiques dans la bande *theta* que les voies de l'hémisphère droit (figure 5.16(b)), puisque cet EEG correspond à une crise dont la zone épileptogène se situe dans le lobe temporal de l'hémisphère gauche.

### 5.3 Conclusion

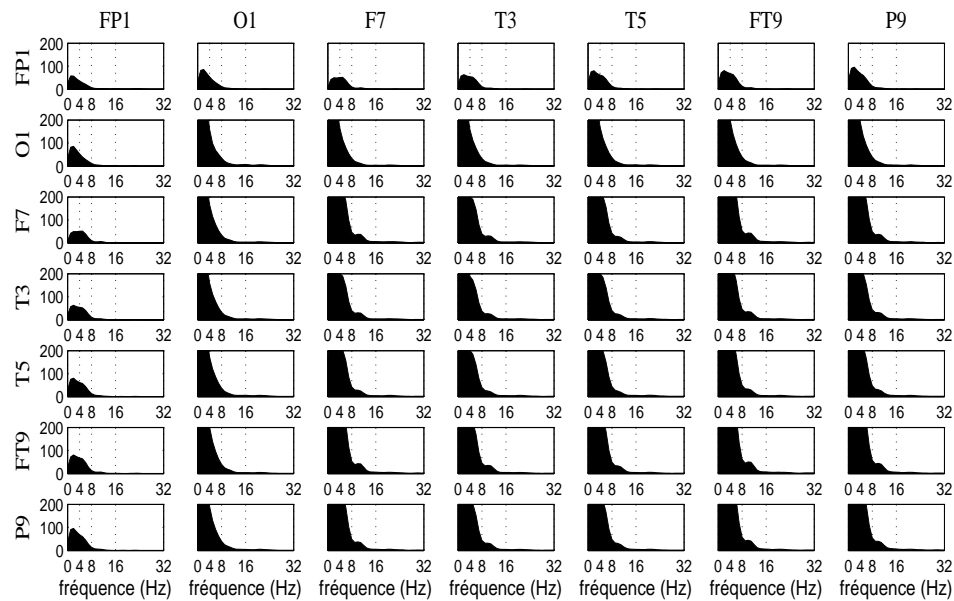
Dans ce dernier chapitre, exploratoire, nous avons présenté plusieurs exemples d'application du pré-traitement développé dans ce mémoire dans une situation réelle d'utilité clinique : les crises d'épilepsie du lobe temporal.

De manière générale, on peut conclure que l'application de la méthodologie automatique pour l'élimination d'artéfacts améliore considérablement l'interprétation médicale pour l'analyse visuelle d'EEG critique. Toutefois, il persiste un risque de perte d'information, non négligeable surtout dans les cas pathologiques. Quelques orientations d'améliorations possibles ont été proposées à la fin de la section 5.1. Elles visent essentiellement l'étape de classification, qui est en fait responsable de l'élimination de l'information.

A travers une deuxième famille d'applications, nous constatons aussi que l'élimination d'artéfacts peut améliorer de façon très remarquable les études automatiques de synchronisation, à la fois pour détecter, latéraliser et localiser les activités épileptiques. Cependant, une validation plus détaillée de cette partie dépasse le cadre de cette recherche et cette évolution est en cours d'exploration dans le cadre de travaux complémentaires développées par des membres de l'équipe. Ils vont permettre ainsi de mettre en exergue, à travers des critères quantitatifs, l'efficacité et la robustesse de ce prétraitement à travers la détection et la caractérisation sur une base de données issue de procédures complètement expertisées du point de vue clinique : localisation précise de la source épileptogène à travers plusieurs modalités de types EEG, SEEG, Imagerie par Rayonnement Magnétique, Tomographie par Emission de Positons, sémiologie des crises et bien évidemment la description précise de l'évolution en dynamique du réseaux épileptogène sous-jacent.

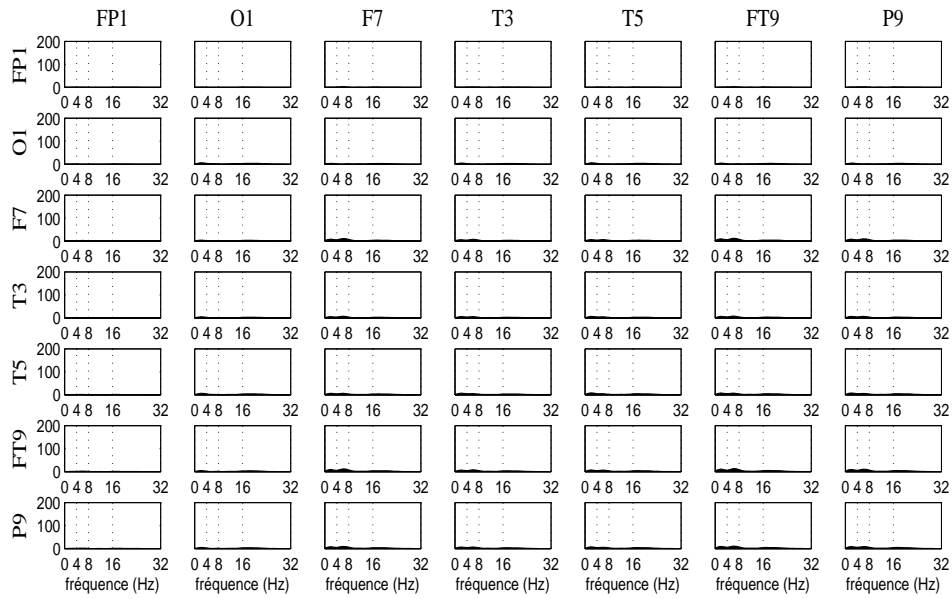


(a) densité spectrale et l'inter-spectre fenêtre (340s 350s) (voir aussi la figure A.27)

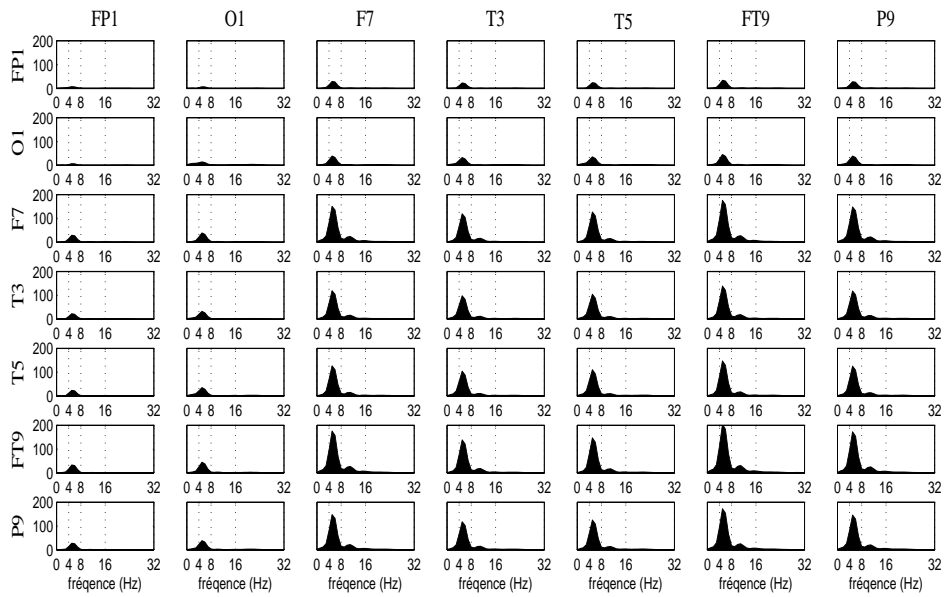


(b) densité spectrale et l'inter-spectre fenêtre (350s 360s) (voir aussi la figure A.28)

**FIGURE 5.13.** Densité spectrale EEG brut critique (hémisphère gauche) voies : Fp1, O1, F7, T3, T5, FT9 et P9

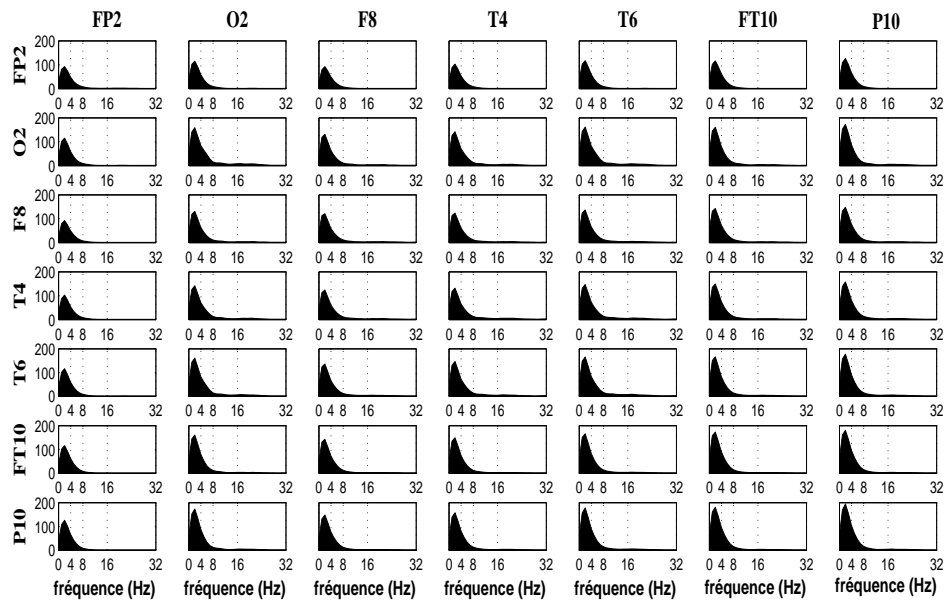


(a) densité spectrale et l'inter-spectre fenêtre (340s 350s) (voir aussi la figure A.29)

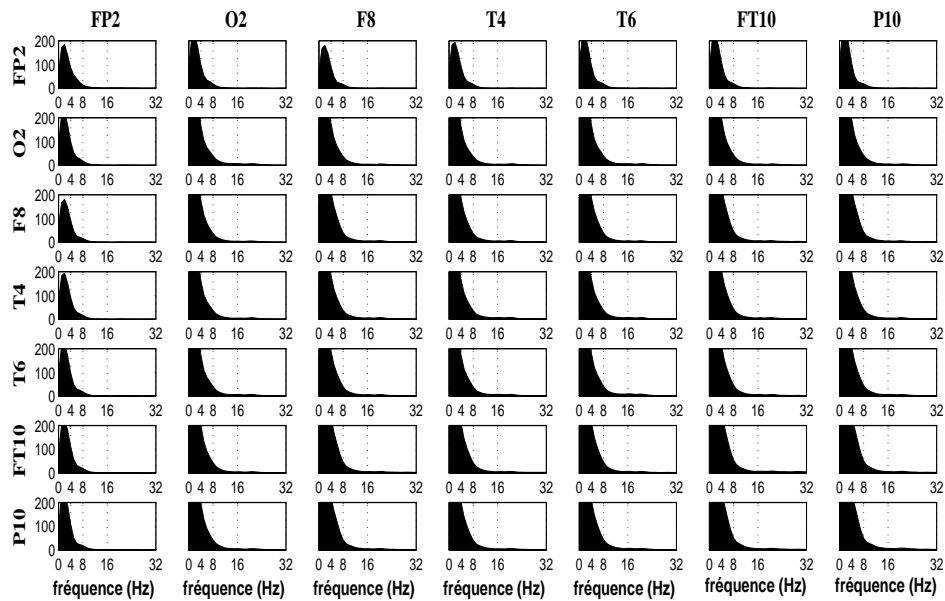


(b) densité spectrale et l'inter-spectre fenêtre (350s 360s) (voir aussi la figure A.30)

**FIGURE 5.14.** Densité spectrale EEG sans artefact critique (hémisphère gauche) voies : Fp1, O1, F7, T3, T5, FT9 et P9

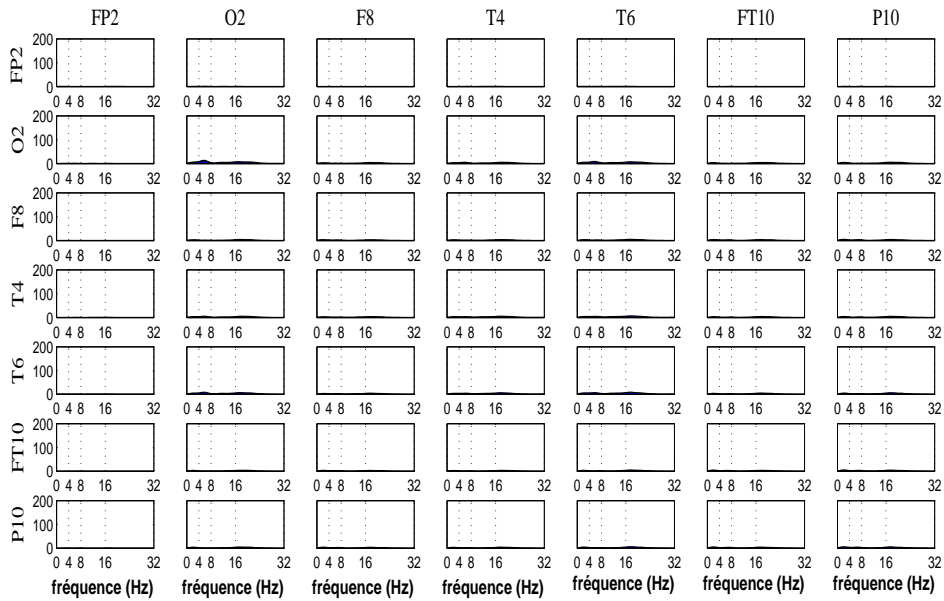


(a) densité spectrale et l'inter-spectre fenêtre (340s 350s) (voir aussi la figure A.31)

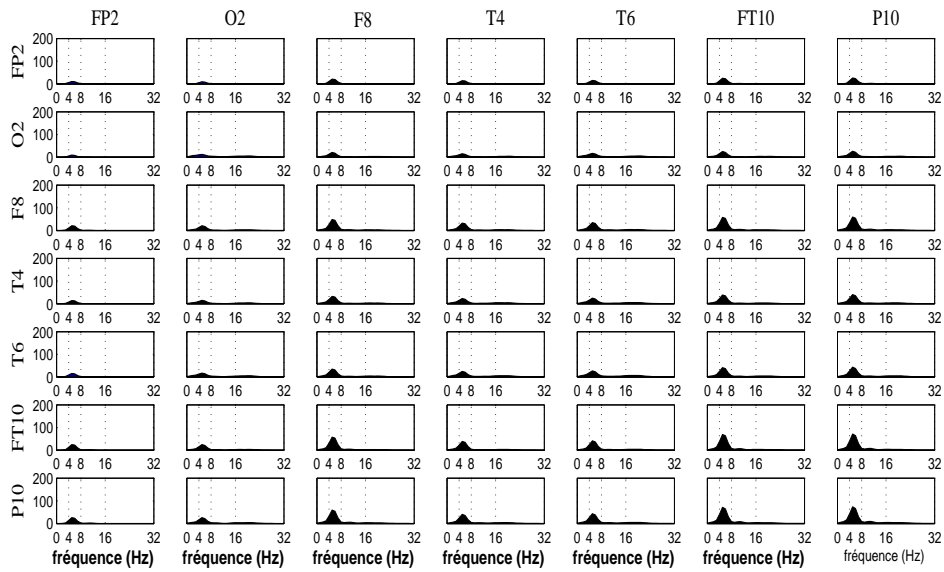


(b) densité spectrale et l'inter-spectre fenêtre (350s 360s) (voir aussi la figure A.32)

**FIGURE 5.15.** Densité spectrale EEG brut critique (hémisphère droit) voies : Fp2, O2, F8, T4, T6, FT10 et P10



(a) densité spectrale et l'inter-spectre fenêtre (340s 350s) (voir aussi la figure A.33)



(b) densité spectrale et l'inter-spectre fenêtre (350s 360s) (voir aussi la figure A.34)

**FIGURE 5.16.** Densité spectrale EEG sans artéfact critique (hémisphère droit) voies : Fp2, O2, F8, T4, T6, FT10 et P10

# Conclusion générale et perspectives

L'EEG de surface a un intérêt fondamental dans le cadre du diagnostic de l'épilepsie. Cette technique est la principale méthode non invasive qui fournit des informations en temps réel sur l'activité électrophysiologique des structures cérébrales et par conséquent sur l'activité épileptique, c'est-à-dire sur les décharges produites lors de crises épileptiques. L'analyse des enregistrements d'EEG fait partie de la démarche diagnostique des médecins et permet de définir le traitement le plus adapté au patient. Cependant, cette analyse (visuelle ou automatique) est souvent très difficile, car les signaux EEG de surface sont fortement perturbés par des artéfacts extra-cérébraux et du bruit de fond.

Cette thèse porte sur la conception d'une méthodologie de traitement consacrée à l'identification des artéfacts (mouvements oculaires, clignements, activité cardiaque, musculaire) et du bruit qui perturbent l'analyse des enregistrements d'EEG, suivi de leur élimination avec une perte minimale d'information. L'automatisation de l'identification et de l'élimination d'artéfacts permettra ultérieurement la reconstruction des signaux d'EEG dits "propres".

Les travaux de recherche présentés ici constituent un travail pluridisciplinaire. Les différentes techniques d'ingénierie biomédicale (et plus particulièrement de traitement du signal) font appel à l'expertise médicale à la fois pour la modélisation du problème, pour le choix des solutions les plus adaptées et pour la validation des résultats obtenus. Ainsi, ce travail méthodologique est composé de trois étapes, qui correspondent aux grandes familles de techniques de traitement de signal utilisées : séparation de sources, classification et débruitage par ondelettes. Les étapes sont adaptées à la fois individuellement et en considérant leurs interactions avec les caractéristiques des signaux traités. Enfin, l'ensemble est appliqué sur une base de données de signaux réels, normaux et pathologiques, obtenus sur des cas cliniques réels, et les résultats sont soumis à l'expertise



médicale.

La première étape a été consacrée à l'étude des différents algorithmes de séparation aveugle de sources (SAS). Actuellement, dans la littérature, on ne trouve pas de travaux comparant objectivement l'efficacité des différents algorithmes de SAS lors qu'ils sont appliqués sur des signaux EEG simulés ou réels, et les équipes travaillant dans le domaine utilisent des algorithmes très différents. Comme une quantification objective est impossible sur des signaux réels (les sources intra-cérébrales sont inconnues même pour les médecins), la quantification de l'efficacité des algorithmes a été faite sur des signaux d'EEG simulés. Un premier travail a donc été la simulation des EEG (sources, mélange et perturbations – bruit et artéfacts). Dans la mesure où la méthode de simulation utilisée est valide, les résultats obtenus dans cette étape indiquent que :

- les algorithmes de SAS basés sur la statistique d'ordre deux sont plus efficaces sur les signaux d'EEG
- les algorithmes basés sur la statistique d'ordre deux à blanchiment robuste semblent plus performants, particulièrement la procédure SOBI-RO.

En conclusion, l'algorithme SOBI-RO est donc sélectionné pour l'application sur signaux réels.

L'objectif de la deuxième étape a été l'identification des sources d'artéfacts après la SAS des signaux réels d'EEG de surface. Les sources ont été classées par une méthode basée explicitement sur les connaissances d'experts neurologues. Afin d'identifier les sources d'artéfact, une combinaison de caractéristiques spatiales, fréquentielles et de similarité avec des signaux de référence a été utilisée. L'originalité de cette partie porte essentiellement sur le fait de séparer automatiquement quatre classes de sources (3 types d'artéfacts et une classe cérébrale). Plus exactement, les caractéristiques des trois classes d'artéfacts ont été estimées à partir d'un ensemble d'apprentissage défini par expertise médicale, la quatrième classe étant constituée par défaut par les sources restantes. Plusieurs algorithmes de classification ont été implémentés, la validation des résultats étant faite de deux manières : une validation quantitative, à travers des indices de performance de type bonne/ mauvaise classification, et une validation qualitative, par expertise subjective médicale, afin de juger de l'intérêt clinique dans le cadre de l'aide au diagnostic et à l'interprétation.

Les nombreux résultats présentés montrent globalement que ce type de prétraitement, basé sur la séparation de sources et la classification automatique, apporte un réel bénéfice pour la lecture, l'analyse et l'interprétation des signaux d'EEG de surface. Néan-

---

moins, quelques problèmes subsistent, notamment dans l'élimination des artéfacts haute-fréquence (musculaires et bruit), qui sont difficilement séparables des sources cérébrales.

La troisième étape propose une solution pour l'amélioration de l'élimination des artéfacts de haute fréquence et du bruit en introduisant une étape de débruitage par ondelettes. Une contrainte importante est la préservation de l'information utile du point de vue clinique : en effet, le bruit doit être éliminé ou réduit, mais sans dénaturer l'information médicale. Deux sous-problèmes sont traités dans cette étape de débruitage : le choix de l'algorithme de débruitage le plus adapté aux signaux d'EEG et, dans un deuxième temps, l'étude des interactions entre le débruitage et la séparation de sources, qui aboutissent au choix d'une combinaison optimale (au sens de l'ordonnancement des étapes).

Les résultats obtenus en simulation montrent que les EEG bruts peuvent être améliorés sans perte d'information en appliquant un algorithme réputé pour fournir des seuils de faible valeurs (et donc une bonne préservation de l'information, mais une élimination partielle du bruit) comme R-SURE. Quant à la combinaison débruitage-SAS, les résultats montrent qu'une mauvaise combinaison risque de déformer les signaux d'EEG. Par exemple, le débruitage des signaux d'EEG avant l'application de la SAS et la classification peut conduire à une mauvaise estimation des sources et du mélange, ainsi qu'à une classification plus difficile. En revanche, un algorithme de débruitage adapté aux signaux d'EEG (*i.e.* R-SURE), appliqué après la séparation et la classification de sources (soit sur le mélange reconstruit, soit sur les sources estimées) semble une solution performante pour l'élimination du bruit. L'amélioration de l'interprétation des signaux d'EEG, tout en préservant l'information sur l'activité cérébrale est ainsi possible. Les résultats obtenus sur les EEG réels avec l'introduction d'une étape de débruitage montrent une amélioration considérable pour l'élimination des artéfacts de haute fréquence et du bruit, en améliorant également l'interprétation et l'analyse visuelle des signaux d'EEG de surface.

Le dernier chapitre illustre la méthodologie développée précédemment sur deux applications d'utilité clinique, sur des signaux EEG pathologiques réels. La première application est celle de l'élimination d'artéfacts et du bruit afin d'améliorer leur interprétation. Les résultats obtenus montrent que l'application de la méthodologie automatique d'élimination d'artéfacts est performante. La méthode de classification la plus performante pour l'identification de sources d'artéfacts est l'analyse discriminante quadratique (classificateur de Bayes). La deuxième application porte sur l'amélioration des résultats des méthodes d'analyse automatique des EEG par des méthodes d'estimation des synchro-

nisations entre les signaux de surface, qui reflètent *a priori* des connexions fonctionnelles entre les différentes structures cérébrales de profondeur. Dans ce cas, nous illustrons l'utilité de l'élimination des artéfacts et du bruit pour la caractérisation de la crise d'épilepsie.

Les résultats de ces deux applications cliniques sont satisfaisantes. Du point de vue médical, l'interprétation de 88% d'EEG épileptiques a été améliorée par cette approche. L'analyse des résultats montre néanmoins une perte d'information non négligeable : 6% des tracés ont été jugés corrompus par les médecins. Nous avons donc proposé une possible première voie pour l'amélioration de l'étape de classification, en introduisant une classe de sources spécifiquement dédiée aux sources épileptiques. Cette approche semble améliorer d'une manière significative les résultats de classification, comme nous l'illustrons sur des exemples d'EEG épileptique. Cependant, l'amélioration de l'interprétation médicale n'a pas encore été validée sur une large base de données.

Du point de vue analyse de synchronisation, les exemples présentés montrent que l'élimination d'artéfacts permet d'étudier les vraies synchronisations dues à l'activité épileptique, en éliminant les synchronisations dues aux artéfacts. Comme pour l'interprétation médicale, la validation de ces premiers résultats est prévue pour des travaux futurs.

D'autres améliorations possibles pourront également être traitées lors des travaux ultérieurs, notamment concernant l'étape de classification. Une étude approfondie pour l'amélioration de l'ensemble d'apprentissage et de caractéristiques choisies, ainsi que l'implémentation et le test d'autres algorithmes de classification constituent des perspectives de recherche.

Un axe prometteur est l'adaptation de ces travaux pour des EEG HR (haute-résolution spatiale), qui modifient fondamentalement le problème de séparation de sources : dans l'hypothèse d'une sur-détermination de la résolution du problème inverse, une étape d'estimation du nombre de sources d'intérêt devient absolument nécessaire, et la place du débruitage devra également être réévaluée (une meilleure séparation de sources peut conduire à un débruitage plus facile et donc à une application avant reconstruction). L'algorithme de séparation, ainsi que le montage EEG d'origine (actuellement en référentiel commun) risquent aussi de modifier les résultats de la SAS : une évaluation sur des signaux simulés plus réalistes pourrait être une perspective très intéressante.

Un résultat relativement peu exploité de la séparation de sources est le modèle de mélange estimé (la matrice de mélange). Pour l'instant, nous l'utilisons pour caractériser certains artéfacts, qui ont une topographie particulière en termes de propagation sur les électrodes de surface. Une analyse plus approfondie de ce modèle pourrait conduire à


---

une caractérisation des crises d'épilepsie, complémentaire à celle fournie par les signaux.

En conclusion, ce travail offre une méthodologie automatique performante pour l'élimination d'artéfacts et du bruit de fond des enregistrements d'EEG, basée sur des méthodes de SAS, du débruitage par ondelettes et de classification supervisée. Les résultats, validés sur des EEG réels d'intérêt clinique, favorisent le diagnostic de l'épilepsie et ouvrent des perspectives de recherche pour améliorer, faciliter et préciser de plus en plus le diagnostic de cette maladie. Finalement, nous voudrions signaler que le sujet abordé dans cette thèse se révèle d'un intérêt social pour les personnes touchés par l'épilepsie, en assurant un diagnostic plus précis ; nous aimerions poursuivre cet axe de recherche, qui mérite d'être encore développé.









Annexe A

FIGURE A.1. EEG brut (version agrandie de la figure 3.3(a))


FIGURE A.2. sources estimées après la SAS (version agrandie de la figure 3.3(b))









**FIGURE A.3.** EEG reconstruit avec les sources identifiées par le système expert (version agrandie de la figure 3.4(a))



**FIGURE A.4.** EEG reconstruit avec les sources identifiées par l'inspection clinique (version agrandie de la figure 3.4(b))



**FIGURE A.5.** EEG reconstruit avec les sources identifiées par la méthode de la distance de Mahalanobis (version agrandie de la figure 3.5(a))



**FIGURE A.6.** EEG reconstruit avec les sources identifiées par le classificateur de Bayes (version agrandie de la figure 3.5(b))





FIGURE A.7. EEG réel (version agrandie des figures 4.10(a) et 5.9(a))

FIGURE A.8. Débruitage global (version agrandie de la figure 4.10(b))








FIGURE A.9. Débruitage local (version agrandie de la figure 4.10(c))




**FIGURE A.10.** EEG reconstruit avec débruitage des sources (avant reconstruction) (version agrandie de la figure 4.11(a))






**FIGURE A.11.** EEG reconstruit débruité (après reconstruction) (version agrandie de la figure 4.11(b))




**FIGURE A.12.** EEG reconstruit avec les sources identifiées par la méthode de la distance de Mahalanobis (version agrandie de la figure 4.12(a))



**FIGURE A.13.** EEG reconstruit avec les sources identifiées par la méthode de la distance de Mahalanobis débruité (version agrandie des figures 4.12(b) et 5.10(a))

FIGURE A.14. EEG brut (version agrandie de la figure 5.1(a))









FIGURE A.15. sources estimées (version agrandie de la figure 5.1(b))



**FIGURE A.16.** inspection clinique (noté 4 selon leur facilité d'interprétation) (version agrandie de la figure 5.2(a))




**FIGURE A.17.** inspection clinique débruité (noté 5 selon leur facilité d'interprétation) (version agrandie de la figure 5.2(b))




**FIGURE A.18.** *distance de Mahalanobis aberruité (noté 4 selon leur facilité d'interprétation) (version agrandie de la figure 5.3(a))*






**FIGURE A.19.** *classificateur de Bayes débruité (noté 4 selon leur facilité d'interprétation) (version agrandie des figures 5.3(b) et 5.12(a))*


FIGURE A.20. EEG critique brut (début crise 350s) (version agrandie de la figure 5.4)






**FIGURE A.21.** EEG brut (début crise 364s) (version agrandie de la figure 5.6(a))


FIGURE A.22. Sources estimées par SAS (version agrandie de la figure 5.6(b))





**FIGURE A.23.** EEG reconstruit par les sources identifiées dans la classe B (4 classes, distance de Mahalanobis) (version agrandie de la figure 5.7)

FIGURE A.24. distance de Mahalanobis (version agrandie de la figure 5.8(a))





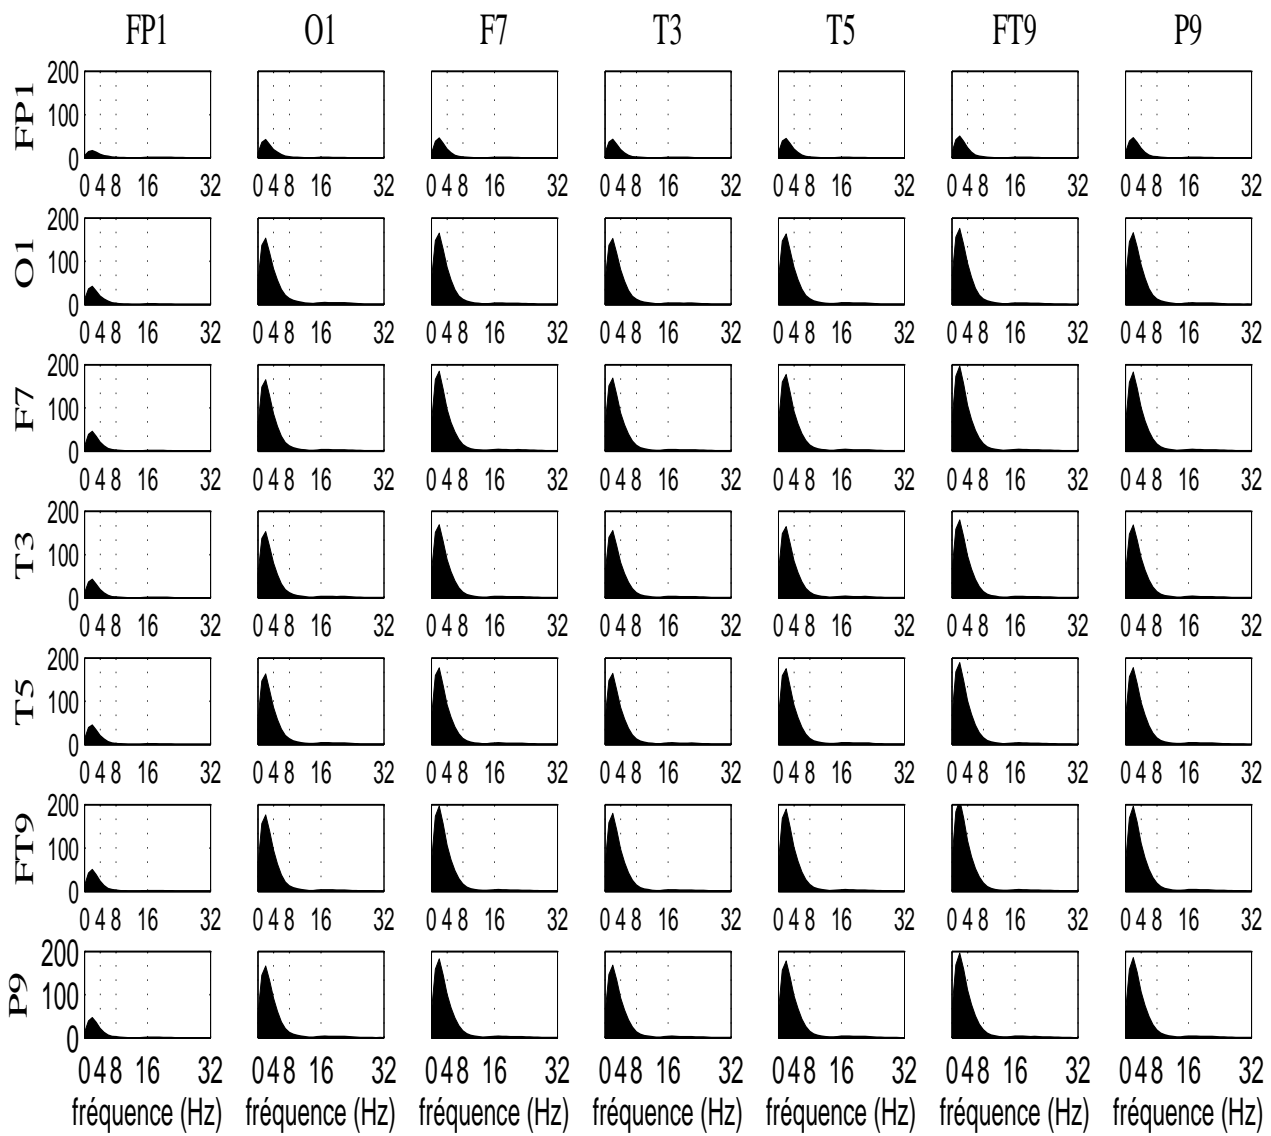


FIGURE A.25. classificateur de Bayes (version agrandie de la figure 5.8(b))

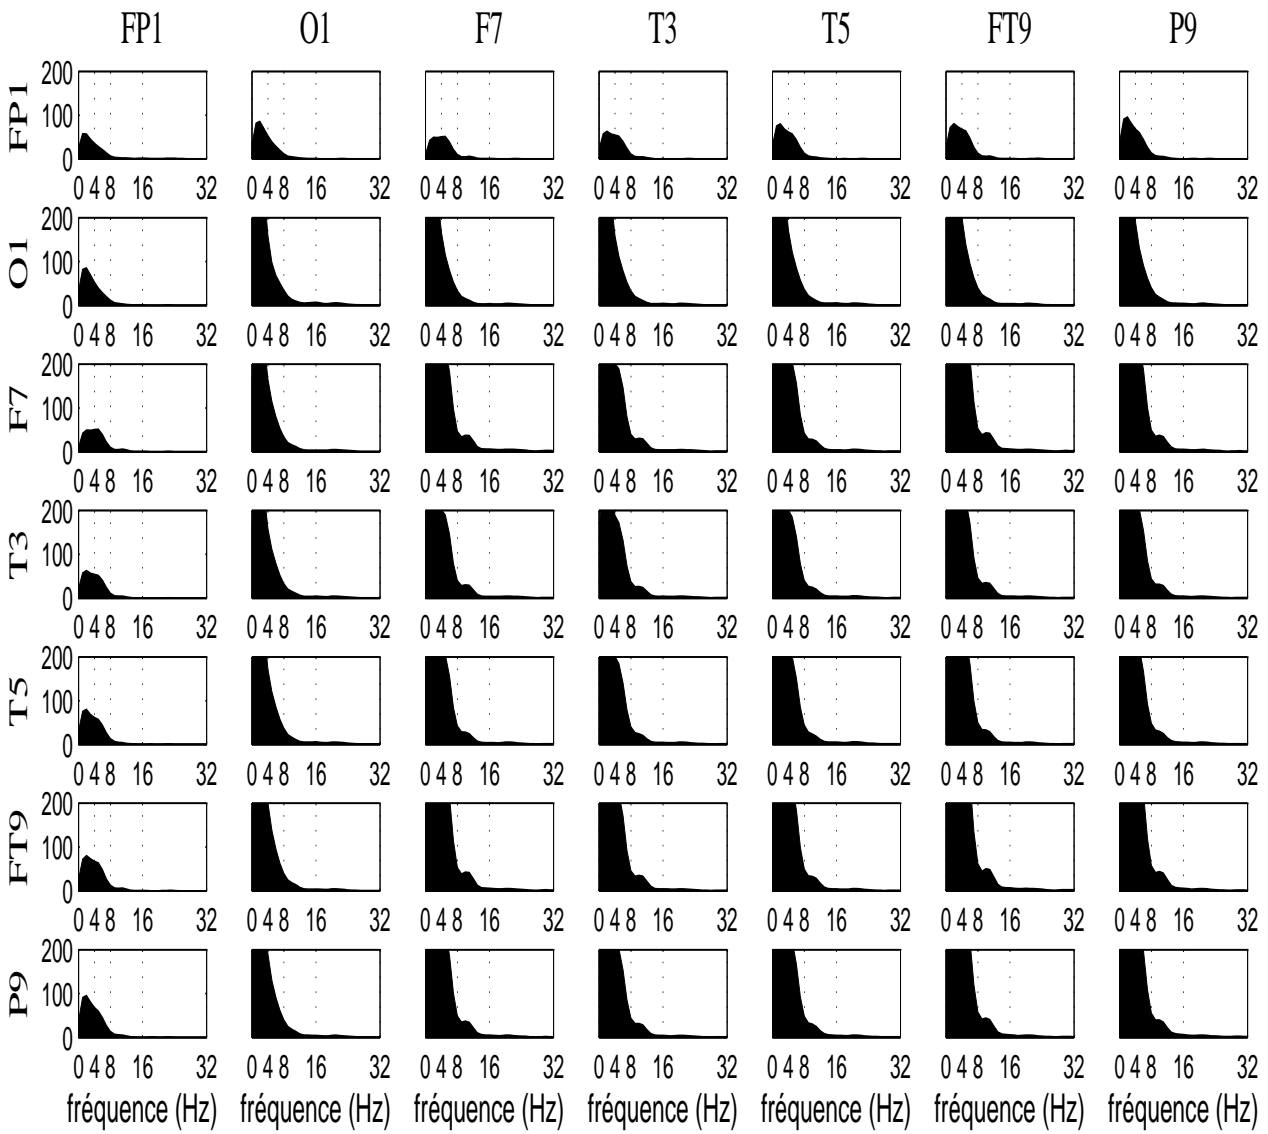


**FIGURE A.26.** EEG brut (début crise 350s) (version agrandie de la figure 5.11(a))

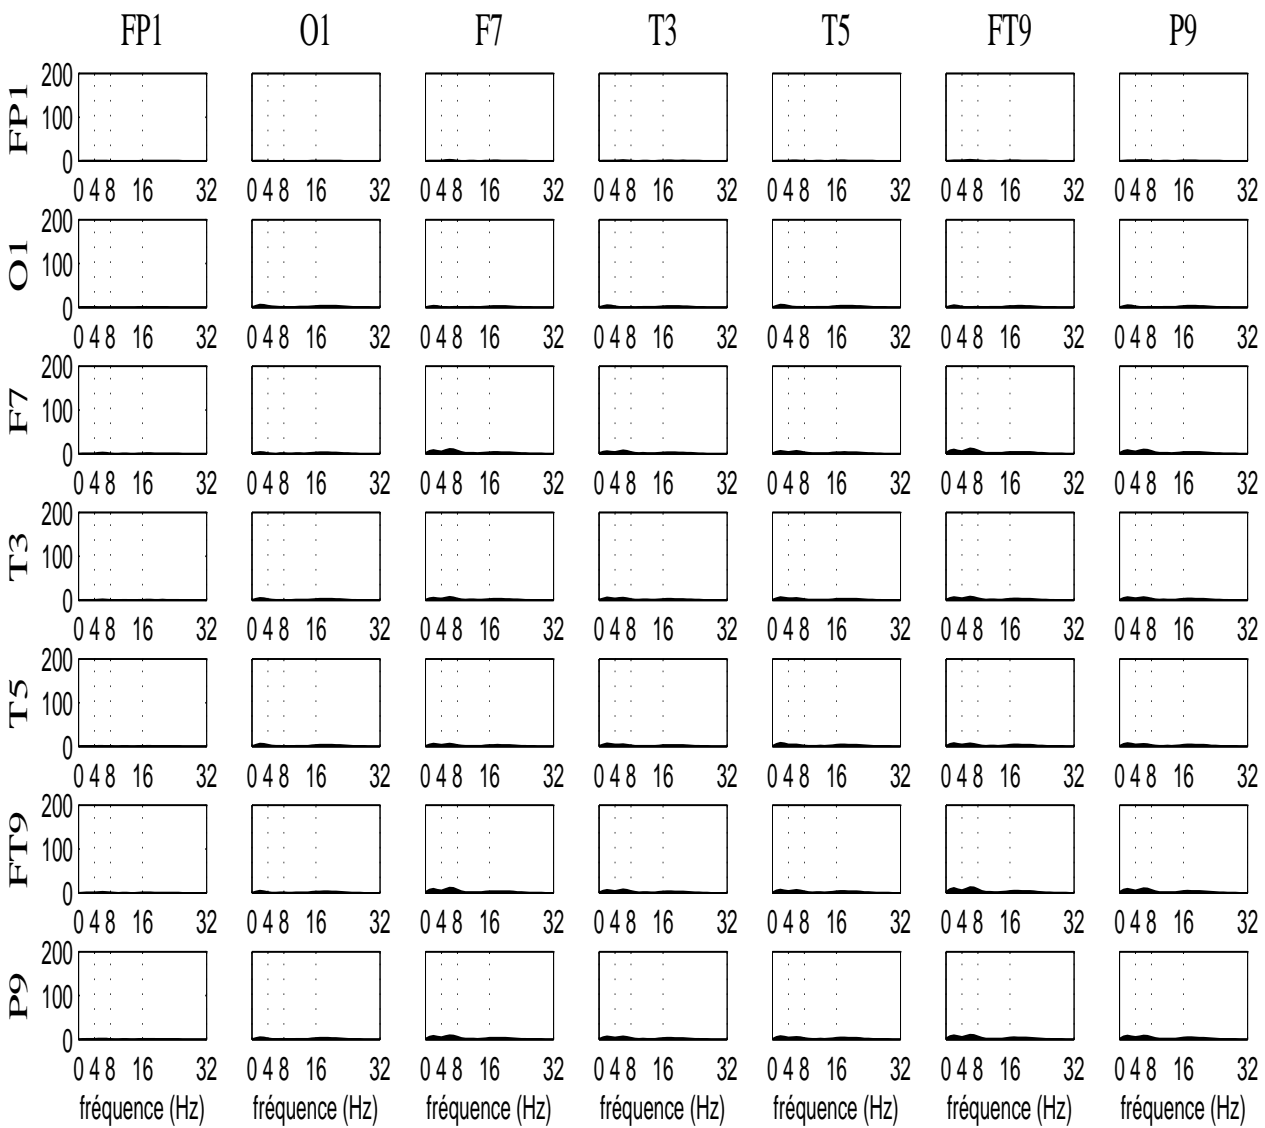




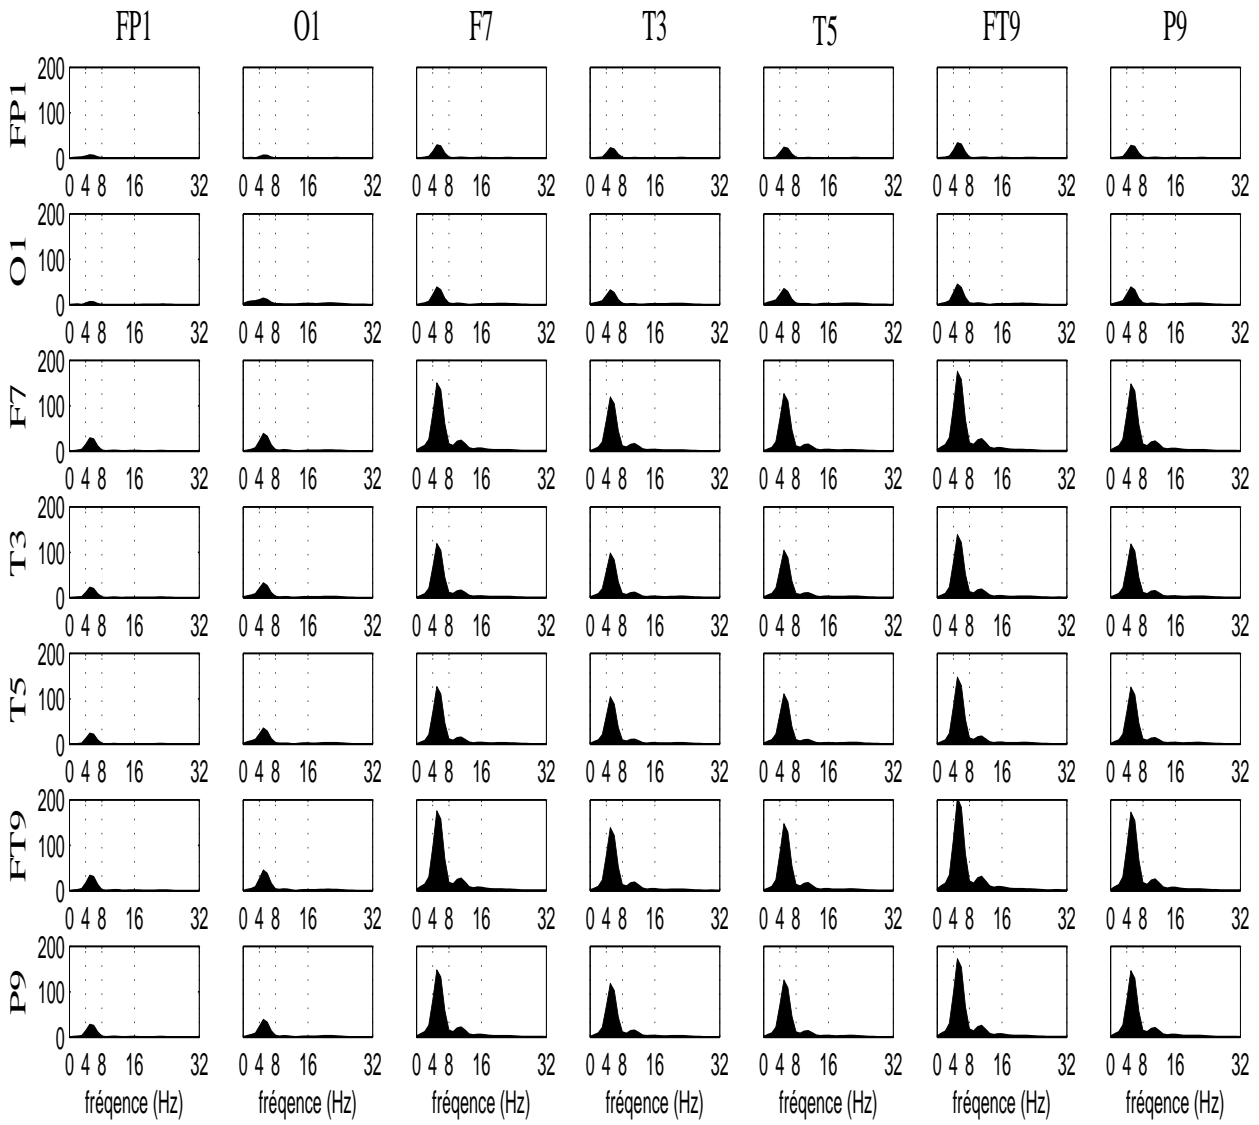
**FIGURE A.27.** densité spectrale et l'inter-spectre EEG brut, fenêtre (340s 350s) (hémisphère gauche) voies : Fp1, O1, F7, T3, T5, FT9 et P9 (version agrandie de la figure 5.13(a))



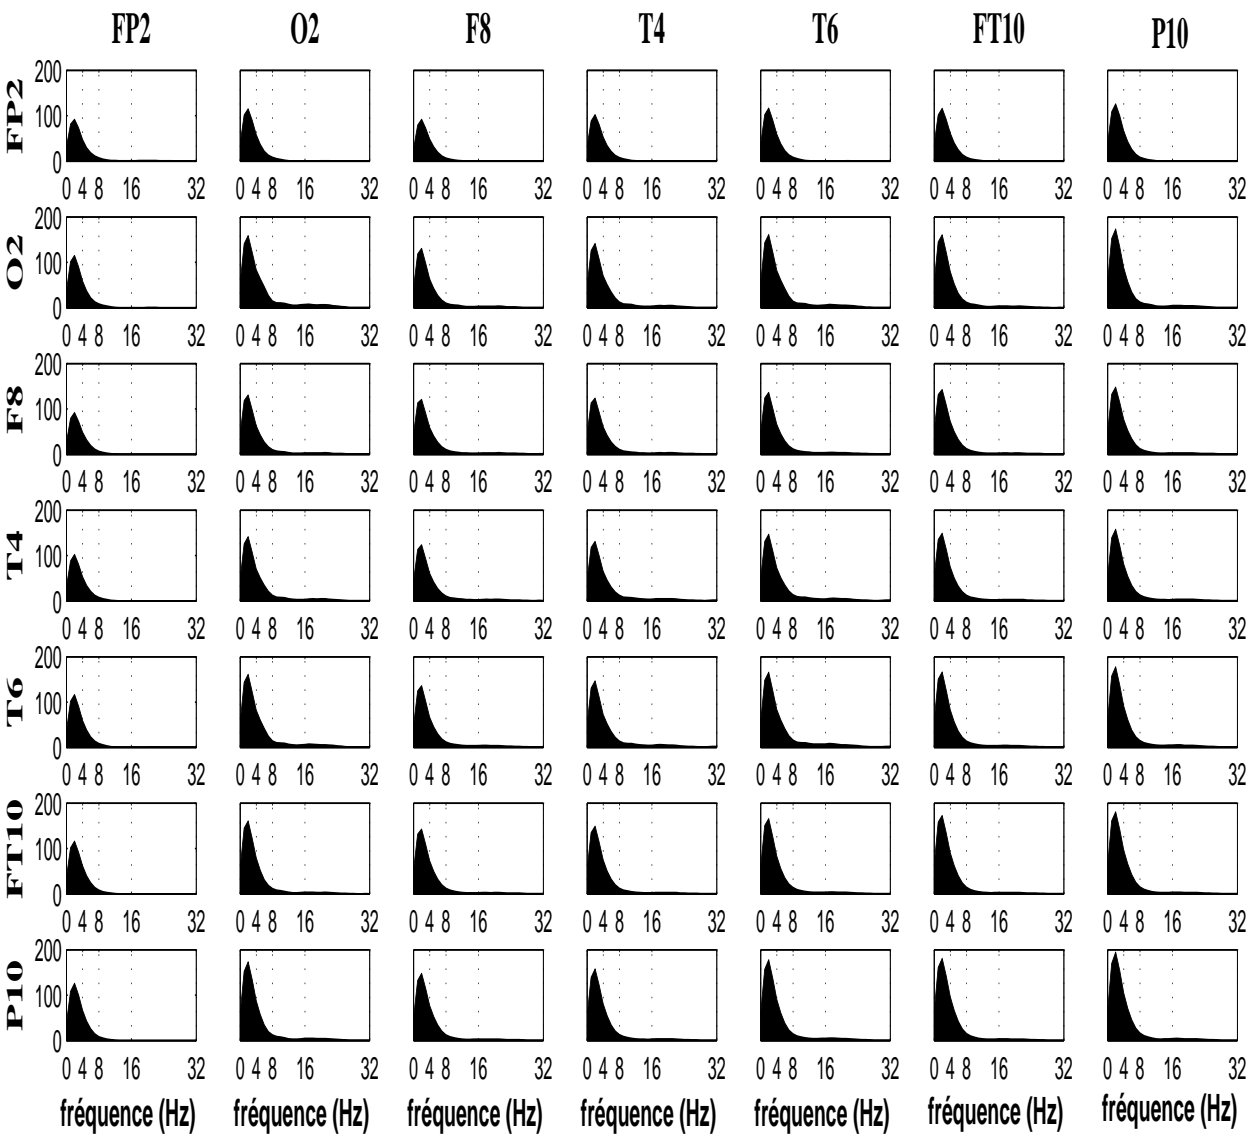
**FIGURE A.28.** densité spectrale et l'inter-spectre EEG brut, fenêtre (350s 360s) (hémisphère gauche) voies : Fp1, O1, F7, T3, T5, FT9 et P9 (version agrandie de la figure 5.13(b))



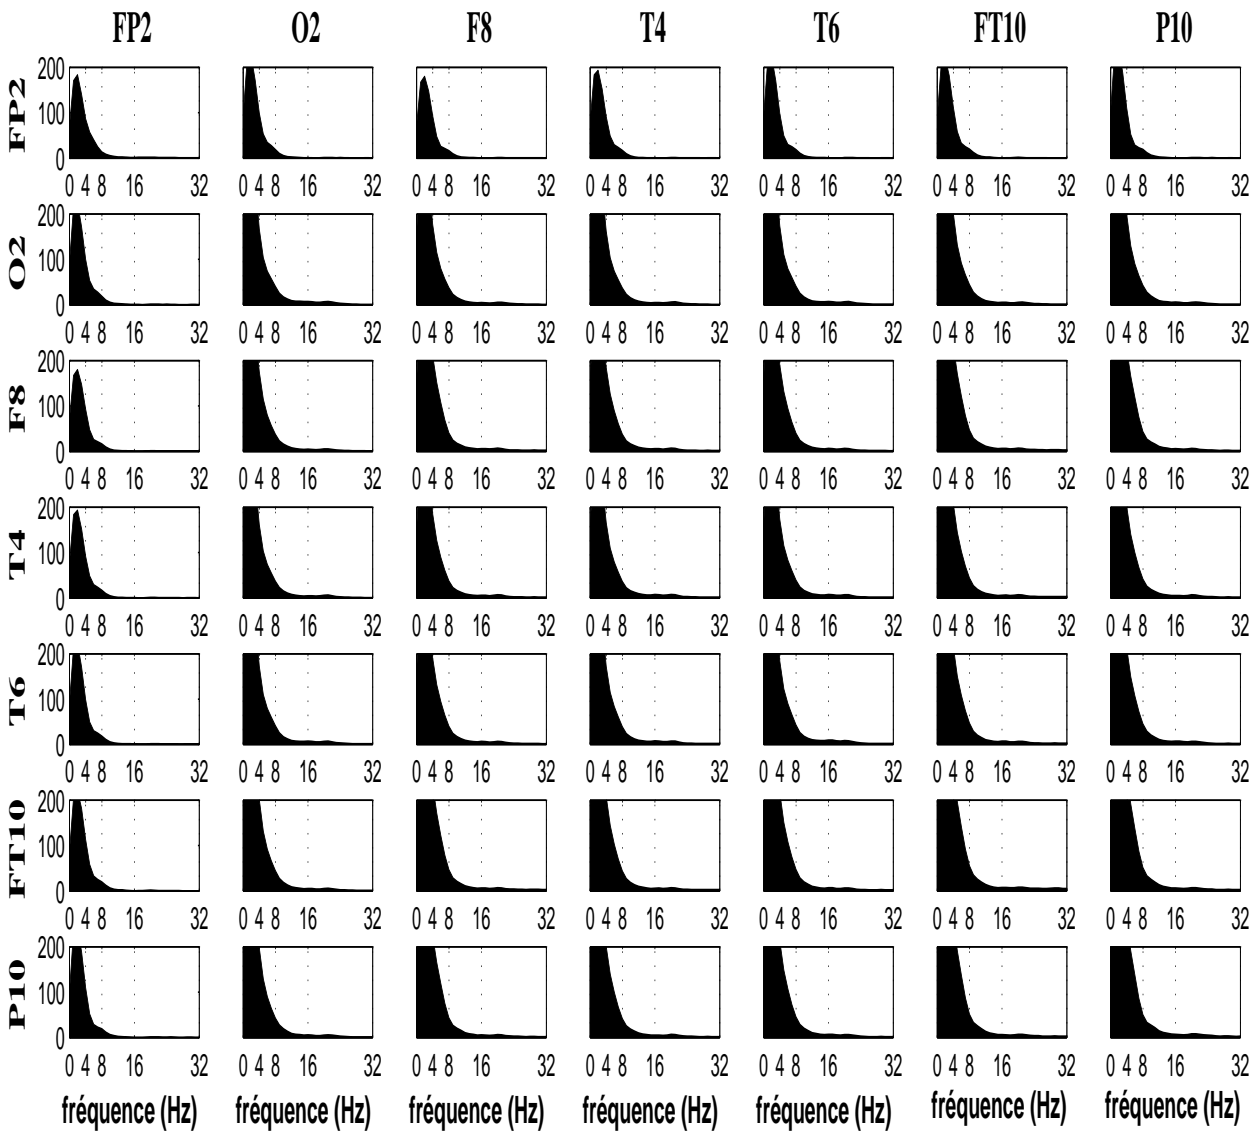
**FIGURE A.29.** densité spectrale et l'inter-spectre EEG sans artéfact critique, fenêtre (340s 350s) (hémisphère gauche) voies : Fp1, O1, F7, T3, T5, FT9 et P9 (version agrandie de la figure 5.14(a))



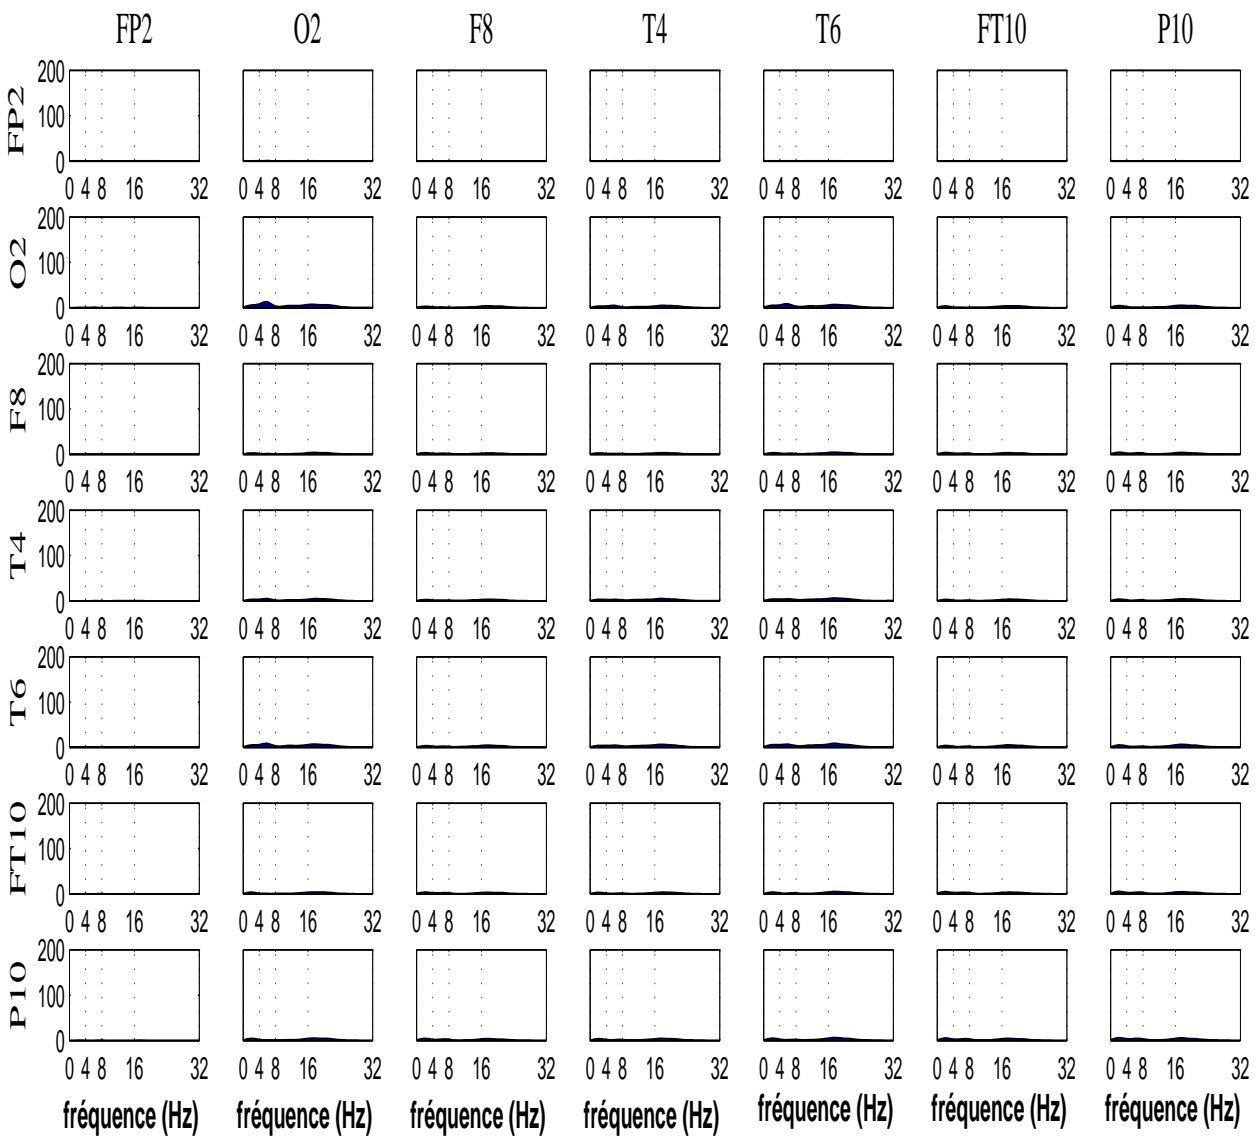
**FIGURE A.30.** densité spectrale et l'inter-spectre EEG sans artéfact critique, fenêtre (350s 360s) (hémisphère gauche) voies : Fp1, O1, F7, T3, T5, FT9 et P9 (version agrandie de la figure 5.14(b))




**FIGURE A.31.** densité spectrale et l'inter-spectre EEG brut, fenêtre (340s 350s) (hémisphère droit) voies : Fp2, O2, F8, T4, T6, FT10 et P10 (version agrandie de la figure 5.15(a))



**FIGURE A.32.** densité spectrale et l'inter-spectre EEG brut, fenêtre (350s-360s) (hémisphère droit) voies : Fp2, O2, F8, T4, T6, FT10 et P10 (version agrandie de la figure 5.15(b))



**FIGURE A.33.** densité spectrale et l'inter-spectre EEG sans artéfact critique, fenêtre (340s 350s) ((Hémisphère droit) voies : Fp2, O2, F8, T4, T6, FT10 et P10 (version agrandie de la figure 5.16(a))



**FIGURE A.34.** densité spectrale et l'inter-spectre EEG sans artéfact critique, fenêtre (350s 360s) (hémisphère droit) voies : Fp2, O2, F8, T4, T6, FT10 et P10 (version agrandie de la figure 5.16(b))





# Bibliographie

- [Achard *et al.*, 2003] ACHARD, S., PHAM, D. et JUTTEN, C. (2003). Quadratic dependence measure for nonlinear blind sources separation. *In 4th International Conference on ICA and BSS*, pages 1–4, Nara, Japan.
- [Adam *et al.*, 2000] ADAM, C., ARZIMANOGLU, M., ans BAULAC, A., BENDRIEM, B., BIRABEN, A., CHIRON, C., DUPONT, S., HIRSCH, E., MARESCAUX, C., SEMAH, F. *et al.* (2000). *Epilepsies, de la clinique aux examens complémentaires : les méthodes (Tome 1)*. Expressions santé éditions.
- [Ans *et al.*, 1985] ANS, B., HÉRAULT, J. et JUTTEN, C. (1985). Adaptive neural architectures : detection of primitives. *In Proc. of COGNITIVA'85*, pages 593–597.
- [Antoniadis *et al.*, 2007] ANTONIADIS, A. *et al.* (2007). Wavelet methods in statistics : Some recent developments and their applications. *Statistics Surveys*, 1:16–55.
- [Antoniadis *et al.*, 2001] ANTONIADIS, A., BIGOT, J. et SAPATINAS, T. (2001). Wavelet estimators in nonparametric regression : a comparative simulation study. *Journal of Statistical Software*, 6(6):1–83.
- [Arnhold *et al.*, 1999] ARNHOLD, J., GRASSBERGER, P., LEHNERTZ, K. et ELGER, C. (1999). A robust method for detecting interdependences : application to intracranially recorded EEG. *Physica D*, 134:419–430.
- [Astolfi *et al.*, 2008] ASTOLFI, L., CINCOTTI, F., MATTIA, D., de VICO FALLANI, F., TOCCI, A., COLOSIMO, A., SALINARI, S., MARCIANI, M., HESSE, W., WITTE, H., URSINO, M., ZAVAGLIA, M. et BABILONI, F. (2008). Tracking the time-varying cortical connectivity patterns by adaptive multivariate estimators. *IEEE Transactions on Biomedical Engineering*, 55(3):902–913.
- [Astolfi *et al.*, 2007] ASTOLFI, L., CINCOTTI, F., MATTIA, D., MARCIANI, M.G. Baccala, L., de VICO FALLANI, F., SALINARI, S., URSINO, M., ZAVAGLIA, M., DING, L., EDGAR, J., MILLER, G., HE, B. et BABILONI, F. (2007). Comparison of different cortical connectivity estimators for high-resolution EEG recordings. *Human Brain Mapping*, 28:143–157.

- [Bacharakis *et al.*, 1996] BACHARAKIS, E., NANDI, A. et ZARZOSO, V. (1996). Foetal ECG extraction using blind source separation methods. *In Proceedings EUSIPCO*, pages 395–398.
- [Bancaud, 1959] BANCAUD, J. (1959). Techniques et méthodes de l’exploration fonctionnelle stéréotaxique des structures encéphaliques chez l’homme (cortex, sous-cortex, noyaux gris centraux). *Rev. Neurol.*, 101:220–227.
- [Bartolomei *et al.*, 2001] BARTOLOMEI, F., WENDLING, F., BELLANGER, J., RÉGIS, J. et CHAUVEL, P. (2001). Neural networks involving the medial temporal structures in temporal lobe epilepsy. *Journal of Clinical Neurophysiology*, 112:1746–1760.
- [Bartolomei *et al.*, 2004] BARTOLOMEI, F., WENDLING, F., RÉGIS, J., GAVARET, M., GUYE, M. et CHAUVEL, P. (2004). Pre-ictal synchronicity in limbic networks of mesial temporal lobe epilepsy. *Epilepsy Research*, 61:89–104.
- [Bell et Sejnowski, 1995] BELL, A. J. et SEJNOWSKI, T. J. (1995). An information-maximization approach to blind separation and blind deconvolution. *Neural Computation*, 7:1129–1159.
- [Belouchrani *et al.*, 1993] BELOUHRANI, A., ABED-MERAIM, K., CARDOSO, J. et MOULINES, E. (1993). Second-order blind separation of temporally correlated sources. *In Proc. Int. Conf. Digital Signal Processing*, pages 346–351.
- [Belouchrani *et al.*, 1997] BELOUHRANI, A., ABED-MERAIM, K., CARDOSO, J. et MOULINES, E. (1997). A blind source separation technique using second-order statistics. *IEEE Transactions on signal processing*, 45(2):434–444.
- [Belouchrani et Amin, 1998] BELOUHRANI, A. et AMIN, M. (1998). Blind source separation based on time-frequency signal representations. *IEEE Transactions on Signal Processing*, 46(11):2888–2897.
- [Belouchrani et Cichocki, 2000] BELOUHRANI, A. et CICHOCKI, A. (2000). Robust whitening procedure in blind source separation context. *Electronics Letters*, 36(24):2050–2053.
- [Berger, 1929] BERGER, H. (1929). Über das elektrenkephalogramm des menschen. *European Archives of Psychiatry and Clinical Neuroscience*, 87(1):527–570.
- [Berryman *et al.*, 2004] BERRYMAN, M., MESSER, S., ALLISON, A. et ABBOTT, D. (2004). Techniques for noise removal from EEG, EOG, and airflow signals in sleep patients. *In Proceedings-SPIE*, volume 5467, pages 89–97.

- 
- [Boashash *et al.*, 2003] BOASHASH, B. *et al.* (2003). *Time frequency signal analysis and processing : a comprehensive reference*. Elsevier Amsterdam.
- [Boudet *et al.*, 2007] BOUDET, S., PEYRODIE, L., GALLOIS, P. et VASSEUR, C. (2007). Filtering by optimal projection and application to automatic artifact removal from EEG. *Signal Processing*, 87(8):1978–1992.
- [Boumaraf *et al.*, 2005] BOUMARAF, H., PHAM, D. et SERVIÈRE, C. (2005). Blind separation of convolutive mixture of speech sources. *In Proceedings of 13th European Signal Processing Conference*.
- [Bourien, 2003] BOURIEN, J. (2003). *Analyse de distributions spatio-temporelles de transitoires dans des signaux vectoriels. Application à la détection-classification d'activités paroxystiques intercritiques dans des observations EEG*. Thèse de doctorat, Université Rennes 1, France.
- [Caparos, 2006] CAPAROS, M. (2006). *Analyse automatique des crises d'épilepsie du lobe temporal à partir des EEG de surface*. Thèse de doctorat, spécialité automatique et traitement du signal, Institut National Polytechnique de Lorraine - INPL, France.
- [Cardoso, 1998] CARDOSO, J. (1998). Blind signal separation : statistical principles. *Proceedings of the IEEE*, 86(10):2009–2025.
- [Cardoso, 1999] CARDOSO, J. (1999). High-order contrasts for independent component analysis. *Neural Computation*, 11(1):157–192.
- [Cardoso et CNRS, 1998] CARDOSO, J. et CNRS, P. (1998). Blind signal separation : statistical principles. *Proceedings of the IEEE*, 86(10):2009–2025.
- [Cardoso et Souloumiac, 1993] CARDOSO, J. et SOULOUMIAC, A. (1993). Blind beamforming for non Gaussian signals. *IEE Proceedings-F*, 40(6):362–370.
- [Cardoso et Souloumiac, 1996] CARDOSO, J.-F. et SOULOUMIAC, A. (1996). Jacobi angles for simultaneous diagonalization. *SIAM J. Mat. Anal. Appl.*, 17(1):161–164.
- [Castellanos et Makarov, 2006] CASTELLANOS, N. et MAKAROV, V. (2006). Recovering EEG brain signals : artifact suppression with wavelet enhanced independent component analysis. *Journal of neuroscience methods*, 158(2):300–312.
- [Cherkassky et Kilts, 2001] CHERKASSKY, V. et KILTS, S. (2001). Comparison of wavelet thresholding methods for denoising ECG signals. volume 2130/2001, pages 625–629.
- [Choi et Cichocki, 2000] CHOI, S. et CICHOCKI, A. (2000). Blind separation of nonstationary sources in noisy mixtures. *Electronics Letters*, 36:848–849.
- [Choi *et al.*, 2002] CHOI, S., CICHOCKI, A. et BELOUHRANI, A. (2002). Second order nonstationary source separation. *Journal of VLSI Signal Processing*, 32:93–104.

- [Choi *et al.*, 2005] CHOI, S., CICHOCKI, A., PARK, H. et LEE, S. (2005). Blind source separation and independent component analysis : A review. *Neural Information Processing-Letters and Reviews*, 6(1):1–57.
- [Churchland et Sejnowski, 1988] CHURCHLAND, P. et SEJNOWSKI, T. (1988). Perspectives on Cognitive Neuroscience. *Science*, 242(4879):741–45.
- [Cichocki et Amari, 2002] CICHOCKI, A. et AMARI, S. (2002). *Adaptive blind signal and image processing : learning algorithms and applications*. Wiley.
- [Cichocki *et al.*, 2009] CICHOCKI, A., AMARI, S., SIWEK, K., TANAKA, T. et PHAN, A. H. (2009). ICAlab toolboxes. <<http://www.bsp.brain.riken.jp/ICALAB>>.
- [Cichocki et Belouchrani, 2001] CICHOCKI, A. et BELOUCHRANI, A. (2001). Sources separation of temporally correlated sources from noisy data using a bank of band-pass filters. In *Proc. of Third International Conference on Independent Component Analysis and Signal Separation (ICA-2001)*, pages 173–178, San Diego, USA.
- [Cohen, 1968] COHEN, D. (1968). Magnetoencephalography : Evidence of magnetic fields produced by alpha-rhythm currents. *Science*, 161(3843):784–786.
- [Coifman et Wickerhauser, 1995] COIFMAN, R. et WICKERHAUSER, M. (1995). Adapted waveform de-noising for medical signals et images. *IEEE Engineering in Medicine and Biology*, 14(5):578–586.
- [Coifman et Wickerhauser, 1998] COIFMAN, R. et WICKERHAUSER, M. (1998). Experiments with adapted wavelet de-noising for medical signals and images. In *Time-Frequency and Wavelets in Biomedical Engineering*, Metin Akay, editor, pages 323–346.
- [Comon, 1991] COMON, P. (1991). Independent component analysis. In J.L. Lacoume, M. A. Lagunas and C. L. Nikias, editors, pages 111–120, Chamrousse, France. International Workshop on High Order Statistics.
- [Comon, 1994] COMON, P. (1994). Independent component analysis, a new concept? *Signal Processing*, 36(3):287–314.
- [Congedo *et al.*, 2008] CONGEDO, M., GOUYPAILLER, C. et JUTTEN, C. (2008). On the blind source separation of human electroencephalogram by approximate joint diagonalization of second order statistics. *Clinical Neurophysiology*, 119(12):2677–2686.
- [Cosandier-Rimélé *et al.*, 2008] COSANDIER-RIMÉLÉ, D., MERLET, I., BADIÉ, J., CHAUVEL, P. et WENDLING, F. (2008). The neuronal sources of EEG : modeling of simultaneous scalp and intracerebral recordings in epilepsy. *Neuroimage*, 42(1):135–146.

- 
- [Cover et Thomas, 1991] COVER, T. et THOMAS, J. (1991). *Elements of Information Theory*. John Wiley & Sons.
- [Cruces et Cichocki, 2003] CRUCES, S. et CICHOCKI, A. (2003). Combining blind source extraction with joint approximate diagonalization : Thin algorithms for ica. *In Proc. of the Fourth Symposium on Independent Component Analysis and Blind Signal Separation*, pages 463–469, Japan.
- [Cruces et al., 2001] CRUCES, S., CICHOCKI, A. et AMARI, S. (2001). Criteria for the simultaneous blind extraction of arbitrary groups of sources. *In 3rd international conference on Independent Component Analysis and Blind Signal Separation*, San Diego, California, USA.
- [Cruces et al., 2000] CRUCES, S., CICHOCKI, A. et CASTEDO, L. (2000). Blind source extraction in gaussian noise. *In In proceedings of the 2nd International Workshop on Independent Component Analysis and Blind Signal Separation (ICA'2000)*, pages 63–68, Helsinki, Finland.
- [Delorme et Makeig, 2004] DELORME, A. et MAKEIG, S. (2004). EEGLab : an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of Neuroscience Methods*, 134(1):9–21.
- [Delorme et Makeig, 2009] DELORME, A. et MAKEIG, S. (2009). *EEGLAB Wikitorial*. <[http://sccn.ucsd.edu/wiki/EEGLAB\\_TUTORIAL\\_OUTLINE](http://sccn.ucsd.edu/wiki/EEGLAB_TUTORIAL_OUTLINE)>.
- [Delorme et al., 2001] DELORME, A., MAKEIG, S. et SEJNOWSKI, T. (2001). Automatic artifact rejection for EEG data using high-order statistics and independent component analysis. *In International workshop on ICA (San Diego, CA)*.
- [Deville, 2003] DEVILLE, Y. (2003). Panorama des applications biomédicales des méthodes de séparation aveugle de sources. *In GRETSI, Groupe d'Etudes du Traitement du Signal et des Images*.
- [Ding, 2006] DING, S. (2006). A power iteration algorithm for ica based on diagonalizations of non-linearized covariance matrix. *In Innovative Computing, Information and Control, ICICIC '06*, volume 2, pages 730–733.
- [Donoho, 1992] DONOHO, D. (1992). De-noising via soft thresholding. Rapport technique, Department of Statistics, Stanford University. <<http://www.stat.stanford.edu/~donoho/Reports/index.html>>.
- [Donoho et Johnstone, 1994] DONOHO, D. et JOHNSTONE, I. (1994). Ideal spatial adaptation via wavelet shrinkage. *Biometrika*, 81:425–455.

- [Donoho et Johnstone, 1995] DONOHO, D. et JOHNSTONE, I. (1995). Adapting to unknown smoothness via wavelet shrinkage. *Journal of the american statistical association*, 90:1200–1224.
- [Duann et al., 2002] DUANN, J. R., JUNG, T. P., KUO, W. J., YEH, T. C., MAKEIG, S., HSIEH, J. et SEJNOWSKI, T. J. (2002). Single-trial variability in event-related bold signals. *Neuroimage*, 15:823–835.
- [Erikson et Koivunen, 2002] ERIKSON, J. et KOIVUNEN, V. (2002). Blind separation of convolutive mixture of speech sources. In *In Proc. EUSIPCO*, pages 565–568.
- [Esposito et al., 2005] ESPOSITO, F., SCARABINO, T., HYVÄRINEN, A., HIMBERG, J., FORMISANO, E., COMANI, S., TEDESCHI, G., GOEBEL, R., SEIFRITZ, E. et SALLE, F. D. (2005). Independent component analysis of fmri group studies by self-organizing clustering. *Neuroimage*, 25(1):193–205.
- [Fadaili et al., 2007] FADAILI, E. M., MOREAU, N. T. et MOREAU, E. (2007). Nonorthogonal joint diagonalization/zero diagonalization for source separation based on time-frequency distributions. *Signal Processing, IEEE Transactions on*, 55(5):1673–1687.
- [Farina et al., 2004] FARINA, D., FEVOTTE, C., DONCARLI, C. et MERLETTI, R. (2004). Blind separation of linear instantaneous mixtures of nonstationary surface myoelectric signals. *Biomedical Engineering, IEEE Transactions on*, 51(9):1555–1567.
- [FFRE, 2009] FFRE (2009). Fondation française pour la recherche sur l'épilepsie. <<http://www.fondation-epilepsie.fr>>.
- [Févotte, 2003] FÉVOTTE, C. (2003). *Approche temps-fréquence pour la séparation aveugle de sources non stationnaires*. Thèse de doctorat, Université de Nantes, France.
- [Ganascia, 1993] GANASCIA, J. G. (1993). *L'intelligence artificielle*. Flammarion (Collection Dominos).
- [García et al., 2003] GARCÍA, G. A., NISHITANI, R. et R. OKUNO, K. A. (2003). Independent component analysis as preprocessing tool for decomposition of surface electrode-array electromyogram. In *4th International Symposium on Independent Component Analysis and Blind Signal Separation (ICA2003)*, pages 191–196, Nara, Japan.
- [Gavaret et al., 2009] GAVARET, M., TRÉBUCHON, A., BARTOLOMEI, F., MARQUIS, P., MCGONIGAL, A., WENDLING, F., REGIS, J., BADIÉ, J. et CHAUVEL, P. (2009). Source localization of scalp-EEG interictal spikes in posterior cortex epilepsies investigated by HR-EEG and SEEG. *Epilepsia*, 50(2):276–289.

- 
- [Georgiev et Cichocki, 2001] GEORGIEV, P. et CICHOCKI, A. (2001). Blind source separation via symmetric eigenvalue decomposition. *In in Proceedings of Sixth International Symposium on Signal Processing and its Applications*, pages 17–20, Kuala Lumpur, Malaysia.
- [Geselowitz, 1998] GESELOWITZ, D. B. (1998). The zero of potential. *IEEE Engineering in Medicine and Biology Magazine*, 17(1):128–132.
- [Ghennioui, 2008] GHENNIoui, H. (2008). *Séparation aveugle de mélanges linéaires convolutifs de sources corrélées*. Informatique et télécommunications, Université Med V-Agdal et Université du Sud-Toulon.
- [Gómez-Herrero et al., 2005] GÓMEZ-HERRERO, G., HUUPPONEN, E., VANRUMSTE, B., VERGULT, A., DE CLERCQ, W., VÄRRI, A., EGIAZARIAN, K., VAN HUFFEL, S. et VAN PAESSCHEN, W. (2005). Independent component analysis of single trial evoked brain reponses : is it reliable ? *In Proc. IEEE/IEE Int. Conf. on Computational Intelligence in Medicine and Healthcare (Costa da Caparica, Portugal)*, pages 69–76.
- [Greco et al., 2006] GRECO, A., MAMMONE, N., MORABITO, F. et VERSACI, M. (2006). Kurtosis, Renyi’s entropy and independent component scalp maps for the automatic artifact rejection from EEG data. *International Journal of Signal Processing*, 2(4):240–244.
- [Greenstein, 2000] GREENSTEIN, A. (2000). *Color atlas of neuroscience : neuroanatomy and neurophysiology*. George Thieme Verlag.
- [Guérit et al., 2002] GUÉRIT, J., MAUGUIÈRE, F. et PLOUIN, P. (2002). Guide pratique de neurophysiologie clinique. Recommandations de la Fédération internationale de neurophysiologie clinique., Traduction française.
- [Hadjileontiadis et al., 2000] HADJILEONTIADIS, L., LIATSOS, L., MAVROGIANNIS, C., ROKKAS, T. et PANAS, S. (2000). Enhancement of bowel sounds by wavelet-based filtering. *IEEE Transactions on Biomedical Engineering*, 47(7):876–886.
- [Haykin, 2000] HAYKIN, S. (2000). *Unsupervised Adaptive Filtering*, volume 1, *Blind Source Separation*. John Wiley & Sons.
- [Héroult et Ans, 1984] HÉRAULT, J. et ANS, B. (1984). Circuits neuronaux à synapses modifiables : décodage de messages composites par apprentissage non supervisé. *C.R. de l’Académie des Sciences*, 299:525–528.
- [Héroult et al., 1985] HÉRAULT, J., JUTTEN, C. et ANS, B. (1985). Détection de grandeurs primitives dans un message composite dans une architecture neuromimétique en apprentissage non supervisé. *In Dixième colloque GRETSI sur le Traitement du Signal et des Images*, pages 1017–1022, Nice, France.



- [Hu *et al.*, 2007] HU, S., STEAD, M. et WORREL, G. (2007). Automatic identification and removal of scalp reference signal for intracranial EEGs based on Independent Component Analysis. *IEEE Transactions on Biomedical Engineering*, 54(9):1560–1572.
- [Hyvärinen, 1999] HYVÄRINEN, A. (1999). Fast and robust fixed-point algorithms for independent component analysis. *IEEE Transactions on Neural Networks*, 10(3):626–634.
- [Hyvärinen et Oja, 1997] HYVÄRINEN, A. et OJA, E. (1997). A fast fixed-point algorithm for independent component analysis. *Neural Computation*, 9(7):1483–1492.
- [Hyvärinen et Oja, 2000] HYVÄRINEN, A. et OJA, E. (2000). Independent component analysis : Algorithms and applications. *Neural Networks*, 13(4–5):411–430.
- [Jallon, 2007] JALLON, P. (2007). *L'Épilepsie*. Le Cavalier Bleu.
- [James et Gibson, 2003] JAMES, C. et GIBSON, O. (2003). Temporally constrained ICA : an application to artifact rejection in electromagnetic brain signal analysis. *IEEE Transactions on Biomedical Engineering*, 50(9):1108–1116.
- [Jasper, 1954] JASPER, H. (1954). *Epilepsy and the functional anatomy of the human brain*, chapitre Electrocorticography, pages 692–738. Little-Brown, Boston.
- [Jasper, 1958] JASPER, H. (1958). The ten-twenty electrode system of the International Federation for Electroencephalography. *Electroencephalography and Clinical Neurophysiology*, 10:371–375.
- [Joyce *et al.*, 2004] JOYCE, C., GORODNITSKY, I. et KUTAS, M. (2004). Automatic removal of eye movement and blink artifacts from EEG data using blind component separation. *Psychophysiology*, 41(2):313–325.
- [Jung *et al.*, 2000a] JUNG, T., MAKEIG, S., HUMPHRIES, C., LEE, T., MCKEOWN, M., IRAGUI, V. et SEJNOWSKI, T. (2000a). Removing electroencephalographic artifacts by blind source separation. *Psychophysiology*, 37(02):163–178.
- [Jung *et al.*, 2000b] JUNG, T., MAKEIG, S., WESTERFIELD, M., TOWNSEND, J., COURCHESNE, E. et SEJNOWSKI, T. (2000b). Removal of eye activity artifacts from visual event-related potentials in normal and clinical subjects. *Clinical Neurophysiology*, 111(10):1745–1758.
- [Jutten et Gribonval, 2003] JUTTEN, C. et GRIBONVAL, R. (2003). L'analyse en composantes indépendantes : un outil puissant pour le traitement de l'information. *In Proc. GRETSI 03*, Paris, France.

- 
- [Jutten et Héroult, 1991] JUTTEN, C. et HÉRAULT, J. (1991). Blind separation of sources, part i : An adaptative algorithm based on neuromimatic architecture. *Signal Processing*, 24(1):1–10.
- [Kachenoura, 2006] KACHENOURA, A. (2006). *Traitement Aveugle de Signaux Biomédicaux*. Traitement du signal et telecommunications, L'Universite de Rennes 1, France.
- [Kastler et al., 2006] KASTLER, B., VETTER, D., PATAY, Z. et GERMAIN, P. (2006). *Comprendre l'IRM : manuel d'auto-apprentissage*. Elsevier Masson.
- [Khalil et al., 1997a] KHALIL, M., DUCHÊNE, J. et MARQUE, C. (1997a). Détection et classification d'évènements en représentation multidimensionnelle. Application sur l'EMG utérin. *In Proceedings XVIème Colloque GRETSI*, pages 331–334, Grenoble, France.
- [Khalil et al., 1997b] KHALIL, M., DUCHÊNE, J., MARQUE, C. et LEMAN, H. (1997b). Detection and classification in uterine electromyography by multiscale representation. *Proceedings of the 19th Annual International Conference of the IEEE*, 4(30):1606–1608.
- [Kierkels et al., 2006] KIERKELS, J., van BOXTEL, G. et VOGTEN, L. (2006). A model-based objective evaluation of eye movement correction in EEG recordings. *IEEE Transactions on Biomedical Engineering*, 53(2):246–253.
- [Kolb et Whishaw, 2002] KOLB, B. et WHISHAW, I. (2002). *Cerveau et comportement*. De Boeck Universite.
- [Koldovský et al., 2006] KOLDOVSKÝ, Z., TICHAVSKÝ, P. et OJA, E. (2006). Efficient variant of algorithm fastica for independent component analysis attaining the cramér-rao lower bound. *IEEE Trans. on Neural Networks*, 17(5):1265–1277.
- [Krishnaveni et al., 2006] KRISHNAVENI, V., JAYARAMAN, S., GUNASEKARAN, A. et RAMADOSS, K. (2006). Automatic Removal of Ocular Artifacts using JADE Algorithm and Neural Network. *International Journal of Intelligent Systems and Technologies*, 1(4):322–333.
- [Lathauwer et al., 2000] LATHAUWER, L. D., MOOR, B. D. et VANDEWALLE, J. (2000). Fetal electrocardiogram extraction by blind source subspace separation. *IEEE Transactions on Biomedical Engineering*, 47(5):567–572.
- [Lee, 1998] LEE, T. (1998). *Independent component analysis : theory and applications*. Kluwer academic publishers Boston.
- [Lehnertz et al., 2001] LEHNERTZ, K., ANDRZEJAK, R., ARNHOLD, J., KREUZ, T., MORMANN, F., RIEKE, C., WIDMAN, G. et ELGER, C. (2001). Nonlinear EEG analysis in

- epilepsy : its possible use for interictal focus localization, seizure anticipation, and prevention. *Journal of Clinical Neurophysiology*, 18(3):209–222.
- [LeVan *et al.*, 2006] LEVAN, P., URRESTARAZU, E. et GOTMAN, J. (2006). A system for automatic artifact removal in ictal scalp EEG based on independent component analysis and Bayesian classification. *Clinical Neurophysiology*, 117(4):912–927.
- [Li *et al.*, 1995] LI, C., ZHENG, C. et TAI, C. (1995). Detection of ECG characteristic points using wavelet transforms. *IEEE Transactions on Biomedical Engineering*, 42(1):21–29.
- [Li et Zhang, 2007] LI, X.-L. et ZHANG, X.-D. (2007). Sequential blind extraction adopting second-order statistics. *IEEE Signal Processing Letters*, 14(1):58–61.
- [Li *et al.*, 2006] LI, Y., MA, Z., LU, W. et LI, Y. (2006). Automatic removal of the eye blink artifact from EEG using an ICA-based template matching approach. *Physiological Measurement*, 27(4):425.
- [Makeig *et al.*, 1996] MAKEIG, A., BELL, A., T.P.-JUNG et SEJNOWSKI, T. J. (1996). Independent component analysis of electroencephalographic data. *D. Touretzky, M. Mozer and M. Hasselmo (Eds). Advances in Neural Information Processing Systems*, 8:145–151.
- [Mallat, 1999] MALLAT, S. (1999). *A wavelet tour of signal processing*. Academic Press.
- [Müller *et al.*, 1999] MÜLLER, K., PHILIPS, P. et ZIEHE, A. (1999). Jadetd : Combining higher-order statistics and temporal information for blind source separation with noise. *In Proc. Int. Workshop on Independent Component Analysis and Blind Separation of Signals (ICA '99)*, Aussois.
- [Mocks et Gasser, 1984] MOCKS, J. et GASSER, T. (1984). How to select epochs of the EEG at rest for quantitative analysis. *Electroencephalography and clinical neurophysiology*, 58(1):89–92.
- [Nguyen-Thi et Jutten, 1995] NGUYEN-THI, H. et JUTTEN, C. (1995). Blind source separation for convolutive mixtures. *Signal Processing*, 45(2):209–229.
- [Nicolaou et Nasuto, 2007] NICOLAOU, N. et NASUTO, S. (2007). Automatic artefact removal from event-related potentials via clustering. *Journal of VLSI Signal Processing*, 48(1):173–183.
- [Nunez et Srinivasan, 2006] NUNEZ, P. et SRINIVASAN, R. (2006). *Electric fields of the brain : the neurophysics of EEG*. Oxford University Press, USA.
- [OMS, 2009] OMS (2009). Organisation mondiale de la santé. <<http://www.who.int/fr/>>.

- 
- [Onton et Makeig, 2006] ONTON, J. et MAKEIG, S. (2006). Information-based modeling of event-related brain dynamics. *Progress in Brain Research*, 159:99–120.
- [Perrin *et al.*, 1989] PERRIN, F., PERNIER, J., BERTRAND, O. et ECHALLIER, J. (1989). Spherical splines for scalp potential and current density mapping. *Electroencephalography and Clinical Neurophysiology*, 72(2):184–187.
- [Prasad *et al.*, 2008] PRASAD, V., SIDDAIAH, P. et RAO, B. P. (2008). Denoising of biological signals using different wavelet based methods and their comparison. *Asian Journal of Information Technology*, 7(4):146–149.
- [Rankine *et al.*, 2007] RANKINE, L., STEVENSON, N., MESBAH, M. et BOASHASH, B. (2007). A nonstationary model of newborn eeg. *Biomedical Engineering, IEEE Transactions on*, 54(1):19–28.
- [Ranta *et al.*, 2005] RANTA, R., LOUIS-DORR, V., HEINRICH, C. et WOLF, D. (2005). Iterative wavelet-based denoising methods and robust outlier detection. *IEEE Signal Processing Letters*, 12(8):557–560.
- [Ranta *et al.*, 2003] RANTA, R., LOUIS-DORR, V., HEINRICH, C., WOLF, D. et GUILLEMIN, F. (2003). Débruitage par ondelettes et segmentation de signaux non-stationnaires : réinterprétation d’un algorithme itératif et application à la phonoentérographie. *Traitement du Signal*, 20(2):119–135.
- [Rivet *et al.*, 2003] RIVET, B., JUTTEN, C. et VIGNERON, V. (2003). Wavelet denoising for blind source separation in noisy mixtures. Rapport technique, INPG, Laboratoire des Images et des Signaux.
- [Rivet *et al.*, 2004] RIVET, B., VIGNERON, V., PARASCHIV-IONESCU, A. et JUTTEN, C. (2004). Wavelet De-noising for Blind Source Separation in Noisy Mixtures. In *Independent component analysis and blind signal separation : fifth international conference, ICA 2004*, Granada, Spain.
- [Romero *et al.*, 2008] ROMERO, S., MAÑANAS, M. et BARBANOJ, M. (2008). A comparative study of automatic techniques for ocular artifact reduction in spontaneous EEG signals based on clinical target variables : A simulation case. *Computers in Biology and Medicine*, 38(3):348–360.
- [Romo-Vázquez *et al.*, 2007a] ROMO-VÁZQUEZ, R., RANTA, R., LOUIS-DORR, V. et MAQUIN, D. (2007a). Ocular artifacts removal in scalp EEG : combining ICA and wavelet denoising. In *5th International Conference on Physics in Signal and Image Processing*, France.

- [Romo-Vázquez *et al.*, 2007b] ROMO-VÁZQUEZ, R., RANTA, R., LOUIS-DORR, V. et MAQUIN, D. (2007b). EEG ocular artefacts and noise removal. *In 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC'07*.
- [Romo-Vázquez *et al.*, 2009] ROMO-VÁZQUEZ, R., VÉLEZ-PÉREZ, H., RANTA, R. et DORR, V. L. (2009). Connectivity estimation of scalp electrodes after preprocessing. application to seizure detection. *In NeuroMath Workshop*, Louvain, Belgique.
- [Rong-Yi et Zhong, 2005] RONG-YI, Y. et ZHONG, C. (2005). Blind source separation of multichannel electroencephalogram based on wavelet transform and ICA. *Chinese Physics*, 14(11):2176–2180.
- [Salido-Ruiz *et al.*, 2009] SALIDO-RUIZ, R., RANTA, R. et LOUIS-DORR, V. (2009). EEG montage analysis in Blind Source Separation. *In IFAC Symposium on Modelling and Control in Biomedical Systems*, Aalborg, Denmark.
- [Salido-Ruiz *et al.*, 2008] SALIDO-RUIZ, R., ROMO-VÁZQUEZ, R., RANTA, R. et LEIJA, L. (2008). Analysis of 5 source separation algorithms on simulated EEG signals. *Research in Computer Science / Special Issue in Electronics and Biomedical Informatics, Computer Science and Informatics*, 35:177–186.
- [Sanei et Chambers, 2007] SANEI, S. et CHAMBERS, J. (2007). *EEG signal processing*. Wiley-Interscience.
- [Semah, 2007] SEMAH, F. (2007). La TEP et la TEMP pour l'étude des épilepsies. *Médecine nucléaire*, 31(6):329–336.
- [Senhadji *et al.*, 1995] SENHADJI, L., BELLANGER, J. et CARRAUT, G. (1995). Détection temps-échelle d'évènements paroxystiques intercritiques en électroencéphalogramme. *Traitement du Signal*, 12(4):357–371.
- [Spatt *et al.*, 1997] SPATT, J., PELZL, G. et MAMOLI, B. (1997). Reliability of automatic and visual analysis of interictal spikes in lateralising an epileptic focus during video-EEG monitoring. *Electroencephalography and clinical neurophysiology*, 103(4):421–425.
- [Särelä et Vigario, 2003] SÄRELÄ, J. et VIGARIO, R. (2003). Overlearning in marginal distribution-based ICA : analysis and solutions. *The Journal of Machine Learning Research*, 4:1447–1469.
- [Stein, 1981] STEIN, C. (1981). Estimation of the mean of a multivariate normal distribution. *The Annals of Statistics*, 9(6):1135–1151.
- [Talairach et Bancaud, 1958] TALAIRACH, J. et BANCAUD, J. (1958). *L'exploration chirurgicale stéréotaxique du lobe temporal dans l'épilepsie temporale*. Masson et Cie.

- 
- [Taleb et Jutten, 1999] TALEB, A. et JUTTEN, C. (1999). Source separation in post non linear mixtures. *IEEE Trans. Signal Processing*, 47(10):2807–2820.
- [Teixeira et al., 2006] TEIXEIRA, A. R., TOMÉ, A. M., LANG, E., GRUBER, P. et da SILVA, A. M. (2006). Automatic Removal of High-Amplitude Artifacts from single-channel Electroencephalograms. *Computer Methods and Programs in Biomedicine*, 83(2):125–138.
- [Theis et al., 2003] THEIS, F., adn C.G PUNTONET, A. J. et LANG, E. W. (2003). Linear geometric ICA : fundamentals and algorithms. *Neural Comput.*, 15(2):419–439.
- [Tichavský et al., 2006a] TICHAVSKÝ, P., KOLDOVSKÝ, Z., DORON, E., YEREDOR, A. et GOMEZ-HERRERO, G. (2006a). Blind signal separation by combining two ica algorithms : Hos-based efica and time structure-based wasobi. *In Proceedings of The 2006 European Signal Processing Conference (EUSIPCO'2006)*.
- [Tichavský et al., 2006b] TICHAVSKÝ, P., KOLDOVSKÝ, Z., DORON, E., YEREDOR, A. et HERRERO, G. G. (2006b). Blind signal separation by combining two ica algorithms : Hos-based efica and time structure-based wasobi. *In Proceedings of The 2006 European Signal Processing Conference (EUSIPCO'2006)*, Florence.
- [Tichavský et al., 2008] TICHAVSKÝ, P., KOLDOVSKÝ, Z., YEREDOR, A., HERRERO, G. G. et DORON, E. (2008). A hybrid technique for blind non-gaussian and time-correlated sources using a multicomponent approach. *Neural Networks, IEEE Transactions*, 19(3): 421–430.
- [Ting et al., 2006] TING, K., FUNG, P., CHANG, C. et CHAN, F. (2006). Automatic correction of artifact from single-trial event-related potentials by blind source separation using second order statistics only. *Medical Engineering and Physics*, 28(8):780–794.
- [Tong et al., 1991] TONG, L., SOON, V., HUANG, Y. F. et LIU, R. (1991). Indeterminacy and identifiability of blind identification. *IEEE Trans. CAS*, 38:499–509.
- [Tran et al., 2004] TRAN, Y., CRAIG, A., BOORD, P. et CRAIG, D. (2004). Using independent component analysis to remove artifact from electroencephalographic measured during stuttered speech. *Med. Biol. Eng. Comput.*, 42:627–633.
- [Unser et Aldroubi, 1996] UNSER, M. et ALDROUBI, A. (1996). A review of wavelets in biomedical applications. *Proceedings of the IEEE*, 84(4):626–638.
- [Vespignani, 1998] VESPIGNANI, H. (1998). *L'EEG de la technique a la clinique*. Novartis.
- [Vigario, 1997] VIGARIO, R. (1997). Extraction of ocular artefacts from EEG using independent component analysis. *Electroencephalography and Clinical Neurophysiology*, 103(3):395–404.

- [Vigário *et al.*, 1998] VIGÁRIO, R. N., JOUSMÄKI, V., HÄMÄLÄINEN, M., HARI, R. et OJA, E. (1998). Independent component analysis for identification of artifacts in magnetoencephalographic recordings. *In Adv. Neural Inf. Process. Syst.*, pages 229–235, Cambridge.
- [Vigneron *et al.*, 2003] VIGNERON, V., PARASCHIV-IONESCU, A., AZANCOT, A., SIBONY, O. et JUTTEN, C. (2003). Fetal electrocardiogram extraction based on non-stationary ICA and wavelet denoising. *In 7th IEEE International Symposium on Signal Processing and its Applications, Paris, France.*
- [Vélez-Pérez, 2010] VÉLEZ-PÉREZ, H. (2010). *Localisation et caractérisation du déroulement de la crise d'épilepsie frontale*. Thèse de doctorat, Institut National Polytechnique de Lorraine, France. (en cours de rédaction).
- [Vollgraf et Obermayer, 2006] VOLLGRAF, R. et OBERMAYER, K. (2006). Quadratic optimization for simultaneous matrix diagonalization. *IEEE Transaction on Signal Processing*, 54(9):3270–3278.
- [Wallstrom *et al.*, 2004] WALLSTROM, G., KASS, R., MILLER, A., COHN, J. et FOX, N. (2004). Automatic correction of ocular artifacts in the EEG : a comparison of regression-based and component-based methods. *International journal of psychophysiology*, 53(2): 105–119.
- [Wendling, 1996] WENDLING, F. (1996). *Mise en correspondance d'observations EEG de profondeur pour la reconnaissance de signatures spatio-temporelles dans les crises d'épilepsie*. Thèse de doctorat, Université de Rennes 1.
- [Wendling *et al.*, 2001] WENDLING, F., BARTOLOMEI, F., BELLANGER, F. et CHAUVEL, P. (2001). Interpretation of interdependencies in epileptic signals using a macroscopic physiological model of the EEG. *Clinical Neurophysiology*, 112(7):1201–1218.
- [Wendling *et al.*, 2005] WENDLING, F., HERNANDEZ, A., BELLANGER, J.-J., CHAUVEL, P. et BARTOLOMEI, F. (2005). Interictal to ictal transition in human temporal lobe epilepsy : Insights from a computational model of intracerebral EEG. *Clinical Neurophysiology*, 22(2):343–356.
- [Westen et Garitte, 2000] WESTEN, D. et GARITTE, C. (2000). *Psychologie : Pensée, cerveau et culture*. De Boeck Université.
- [Williams et Herrup, 1988] WILLIAMS, R. W. et HERRUP, K. (1988). The control of neuron number. *Annual Review of Neuroscience*, 11:423–453.

- 
- [Xi-Lin et Xian-Da, 2007] XI-LIN, L. et XIAN-DA, Z. (2007). Non-orthogonal joint diagonalization free of degenerate solution. *IEEE Transactions on Signal Processing*, 55(1): 1803–1814.
- [Yeredor, 2000] YEREDOR, A. (2000). Blind separation of gaussian sources via second-order statistics with asymptotically optimal weighting. *IEEE Signal Processing Letters*, 7:197–200.
- [Zavaglia et al., 2008] ZAVAGLIA, M., ASTOLFI, L., BABILONI, F. et URSINO, M. (2008). The effect of connectivity on EEG rhythms, power spectral density and coherence among coupled neural populations : analysis with a neural mass model. *IEEE Transactions on Biomedical Engineering*, 55(1):69–77.
- [Zhai et Yao, 2004] ZHAI, Y. et YAO, D. (2004). A study on the reference electrode standardization technique for a realistic head model. *Computer Methods and Programs in Biomedicine*, 76(3):229–238.
- [Zibulevsky et Pearlmutter, 2001] ZIBULEVSKY, M. et PEARLMUTTER, B. (2001). Blind source separation by sparse decomposition in a signal dictionary. *Neural Computation*, 13(4):863–882.
- [Ziehe et Müller, 1998] ZIEHE, A. et MÜLLER, K.-R. (1998). TDSEP - an efficient algorithm for blind separation using time structure. *In Proc. ICANN*, pages 675–680.





## Résumé

L'objectif principal de cette thèse est le pré-traitement des signaux d'électroencéphalographie (EEG). En particulier, elle vise à développer une méthodologie pour obtenir un EEG dit "propre" à travers l'identification et l'élimination des artéfacts extra-cérébraux (mouvements oculaires, clignements, activité cardiaque et musculaire) et du bruit. Après identification, les artéfacts et le bruit doivent être éliminés avec une perte minimale d'information, car dans le cas d'EEG, il est de grande importance de ne pas perdre d'information potentiellement utile à l'analyse (visuelle ou automatique) et donc au diagnostic médical.

Plusieurs étapes sont nécessaires pour atteindre cet objectif : séparation et identification des sources d'artéfacts, élimination du bruit de mesure et reconstruction de l'EEG "propre". A travers une approche de type séparation aveugle de sources (SAS), la première partie vise donc à séparer les signaux EEG dans des sources informatives cérébrales et des sources d'artéfacts extra-cérébraux à éliminer. Une deuxième partie vise à classifier et éliminer les sources d'artéfacts et elle consiste en une étape de classification supervisée. Le bruit de mesure, quant à lui, il est éliminé par une approche de type débruitage par ondelettes. La mise en place d'une méthodologie intégrant d'une manière optimale ces trois techniques (séparation de sources, classification supervisée et débruitage par ondelettes) constitue l'apport principal de cette thèse.

La méthodologie développée, ainsi que les résultats obtenus sur une base de signaux d'EEG réels (critiques et inter-critiques) importante, sont soumis à une expertise médicale approfondie, qui valide l'approche proposée.

**Mots-clés:** pré-traitement, EEG, élimination des artéfacts, séparation aveugle de sources, classification supervisée, débruitage par ondelettes, validation médicale

## Abstract

The goal of this research is the electroencephalographic (EEG) signals preprocessing. More precisely, we aim to develop a methodology to obtain a "clean" EEG through the extra-cerebral artefacts (ocular movements, eye blinks, high frequency and cardiac activity) and noise identification and elimination. After identification, the artefacts and noise must be eliminated with a minimal loss of cerebral activity information, as this information is potentially useful to the analysis (visual or automatic) and therefore to the medical diagnosis. To accomplish this objective, several pre-processing steps are needed : separation and identification of the artefact sources, noise elimination and "clean" EEG reconstruction. Through a blind source separation (BSS) approach, the first step aims to separate the EEG signals into informative and artefact sources. Once the sources are separated, the second step is to classify and to eliminate the identified artefacts sources. This step implies a supervised classification. The EEG is reconstructed only from informative sources. The noise is finally eliminated using a wavelet denoising approach. A methodology ensuring an optimal interaction of these three techniques (BSS, classification and wavelet denoising) is the main contribution of this thesis. The methodology developed here, as well the obtained results from an important real EEG data base (ictal and inter-ictal) is subjected to a detailed analysis by medical expertise, which validates the proposed approach.

**Keywords:** EEG preprocessing, artefacts elimination, blind source separation, supervised classification, wavelet denoising, medical validation

